



**UNIVERSIDADE ESTADUAL DE CAMPINAS**  
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

**José Antonio Moreira Schewinsky Junior**

**Uso de Técnicas de Inteligência Artificial: Análise de Sentimento das  
comunicações do Banco Central e correlação com o preço de Ativos  
Financeiros**

Orientador: Prof. Dr. Romis Attux

Co-Orientador: Fábio Gabrielli Fernandes

Campinas

2024

# **Uso de Técnicas de Inteligência Artificial: Análise de Sentimento das comunicações do Banco Central e correlação com o preço de Ativos Financeiros**

Trabalho de Conclusão de Curso submetido à Universidade Estadual de Campinas, como requisito necessário para obtenção do grau de Bacharel em Engenharia Elétrica pela Faculdade de Engenharia Elétrica e de Computação.

Campinas

2024

**UNIVERSIDADE ESTADUAL DE CAMPINAS**

JOSÉ ANTONIO MOREIRA SCHEWINSKY JUNIOR

Esta Monografia foi julgada adequada para a obtenção do título de Bacharel em Engenharia Elétrica, sendo aprovada em sua forma final pela banca examinadora:

---

Orientador(a): Prof. Dr. Romis Attux  
DCA/FEEC/UNICAMP  
Universidade Estadual de Campinas

---

Co - Orientador(a): Fábio Gabrielli Fernandes  
Banco Central do Brasil

---

José Antonio Moreira Schewinsky Junior  
Faculdade de Engenharia Elétrica e de Computação  
Universidade Estadual de Campinas

Todas as opiniões sobre política monetária, cambial, fiscal, de juros entre outros assuntos financeiros contidas neste trabalho são opiniões do aluno e dos orientadores, e não representam uma posição oficial do Banco Central.

Campinas

2024

## **Agradecimentos**

Agradeço primeiramente aos meus familiares por todo o apoio durante minha jornada acadêmica, me acolhendo, me incentivando, me ensinando e me motivando, principalmente nos momentos mais difíceis.

Agradeço também aos meus amigos, minha namorada, e a todos os professores com os quais tive o privilégio de aprender, e que contribuíram em meu desenvolvimento pessoal e intelectual.

Um agradecimento especial ao orientador Prof. Dr. Romis Attux e ao co-orientador Fábio Gabrielli Fernandes, que aceitaram o desafio de desenvolver esse trabalho junto comigo, e tiveram papel fundamental na elaboração, me guiando, ensinando e apoiando.

Também agradeço ao Instituto Federal de São Paulo - IFSP - e à Universidade Estadual de Campinas - Unicamp - em especial à Faculdade de Engenharia Elétrica e Computação - FEEC - por todos os ensinamentos.

## Resumo

A presente pesquisa tem como objetivo principal contribuir para o entendimento acerca de como a comunicação de políticas econômicas influenciam ativos financeiros, especialmente o mercado de ações e taxas de juros, por meio de uma investigação do sentimento presente nas comunicações do Comitê de Política Monetária (COPOM) do Banco Central do Brasil (BCB) e do cálculo da correlação com o preço desses ativos financeiros.

A motivação se deu pela importância direta das taxas de juros na vida cotidiana das pessoas, que está muito além do mercado financeiro, influenciando desde o custo do crédito e financiamento de imóveis até as taxas de poupança e investimento. Alterações nas políticas de juros afetam diretamente a economia real, impactando consumo, emprego e crescimento econômico, tornando o Banco Central um importante instrumento para funcionamento do Estado como motor central da economia, conforme proposto por Keynes (1936). A importância do Banco Central está também em proteger o país das flutuações externas, garantindo a soberania nacional, como destacado por Nieri (2021).

Este trabalho enfatiza a importância de uma comunicação eficaz por parte dos bancos centrais e formuladores de políticas, a fim de garantir que suas intenções sejam compreendidas pelos agentes de mercado, minimizando assim a volatilidade desnecessária. Também trata sobre a capacidade dos agentes econômicos de compreender os objetivos das ações econômicas futuras tomadas pelos formuladores de políticas econômicas, por meio da comunicação que estes realizam. Conforme dito por um dos responsáveis por essa comunicação no Banco Central Americano, Bernanke, “Influenciar as expectativas do público sobre ações políticas futuras tornou-se uma ferramenta crítica (...)” (2011 p. 2, tradução própria).

O estudo realizado por Máté, Sebők e Barczikay (2021) analisou como a comunicação pública do Conselho Monetário do Banco Central da Hungria

afetou os rendimentos dos títulos soberanos húngaros. Aplicando técnicas de análise de texto, como um dicionário de sentimentos, os autores encontraram que o *forward guidance* tem um efeito intra-anual nas expectativas de mercado, nos rendimentos dos títulos e na volatilidade das taxas de juros.

A integração de técnicas de aprendizado de máquina com análises macroeconômicas proporciona uma nova perspectiva na previsão e interpretação de dados econômicos. Utilizando modelos avançados de processamento de linguagem natural, é possível analisar grandes volumes de comunicações e documentos econômicos com maior precisão.

Estes modelos permitem identificar tendências implícitas e prever reações de mercado com base nas comunicações do Banco Central, enriquecendo a análise tradicional e oferecendo *insights* mais profundos sobre a política econômica, conforme discutido por Doh, Kim e Yang (2021).

Desta forma, a capacidade de prever a reação de mercado com base em análise de sentimento é uma importante ferramenta para balizar a formulação de políticas econômicas eficazes através de uma comunicação clara e estratégica, conhecida como *forward guidance*.

*Forward guidance* é a prática de orientar as expectativas do mercado sobre a futura trajetória das políticas monetárias, influenciando assim as decisões econômicas dos agentes no presente, conforme destacado por Moller e Rechmann (2021). Historicamente, a política monetária era conduzida principalmente através do controle de taxas de juros de curto prazo, mas, com o tempo, o papel da comunicação e da transparência aumentou significativamente, principalmente após a Crise de 2008, conforme destacado por Alfieri, Eratalay, Lapitskaya e Sharma (2022).

O estudo de Máté, Sebök e Barczikay (2021), realizado na Hungria, também corrobora essa evolução, mostrando que a comunicação do Banco Central Europeu pode influenciar diretamente os retornos dos ativos financeiros, mesmo em economias fora da zona do euro. O estudo também mostrou que a eficácia do *forward guidance* varia de acordo com a jurisdição e o contexto econômico específico de cada país.

No contexto do Banco Central Europeu, por exemplo, a análise das comunicações revelou que a ordem e a ênfase das mensagens pode alterar significativamente as expectativas do mercado, conforme discutido por Alfieri, Eratalay, Lapitskaya e Sharma (2022).

Neste trabalho, inicialmente foi realizada uma revisão bibliográfica abrangente sobre análise de sentimento e sua aplicação no mercado financeiro, destacando estudos que demonstram a influência das comunicações de bancos centrais sobre os mercados. Foram coletados comunicados do Banco Central do Brasil, a partir de todas as comunicações disponíveis e foram utilizadas apenas as comunicações divulgadas durante o período de câmbio flutuante, de forma a garantir maior robustez da análise.

Foram utilizados algoritmos de processamento de linguagem natural (PLN), de modelos de pares tópico / modificador e modelos de inteligência artificial pré-treinados como o BERT (*Bidirectional Encoder Representations from Transformers*), para classificar os sentimentos em categorias positivas, negativas e neutras, em uma escala que varia de -1 até 1, como feito por Doh, Kim e Yang (2021).

Com os dados de sentimento em mãos, foi aplicada a análise de correlação para investigar a relação entre o sentimento das comunicações do BCB e as variações diárias nos preços dos ativos financeiros selecionados. Os resultados indicam que existe uma correlação entre o sentimento das comunicações do BCB e as variações nos preços dos ativos financeiros.

Especificamente, comunicados com tom positivo tendem a estar associados a aumentos nos preços das ações e diminuição da mediana das expectativas de mercado para juros para o futuro. Já os comunicados com tom negativo tendem a estar associados a quedas nos preços das ações e aumentos da mediana das expectativas de mercado para juros para o futuro. Estes achados sugerem que o mercado financeiro, que pode ser entendido como um *proxy* rápido para a economia real, reage não apenas ao conteúdo explícito das políticas anunciadas, mas também ao sentimento implícito nas comunicações.

Por fim, este estudo destaca a relevância da transparência e da clareza nas comunicações do Banco Central, sugerindo áreas para possíveis pesquisas futuras, como a expansão do escopo para incluir outros tipos de comunicação do BCB e de outros bancos centrais. A análise de sentimento, portanto, pode servir como uma ferramenta complementar na formulação de políticas econômicas, ajudando a prever reações do mercado e ajustando a comunicação para alcançar os objetivos desejados.

**Palavras-chave:** análise de sentimento; Aprendizagem de máquina; Dados; Taxas de juros; Macroeconomia; Banco Central.

## Lista de ilustrações

|   |    |
|---|----|
| Figura 1 – Modelos de Aprendizado de Máquina propostos por Mahesh . . .   | 19 |
| Figura 2 – Arquitetura de Redes Neurais . . . . .   | 21 |
| Figura 3 – Fluxograma do Algoritmo de tópico/modificador em Alto Nível ..   | 45 |
| Figura 4 – Fluxograma do Algoritmo de treinamento para o Tópico/Modificador . . . . .                                       | 47 |
| Figura 5 – Fluxograma do Algoritmo para cálculo do índice de sentimentos usando BERT em Alto Nível . . . . .                | 49 |
| Figura 6 – Fluxograma do Algoritmo de treinamento usando BERT em Alto Nível . . . . .                                       | 49 |
| Figura 7 – Ranking de palavras mais usadas nos comunicados do COPOM em todo o período de divulgação de atas . . . . .       | 51 |
| Figura 8 – Nuvem de palavras mais usadas nos comunicados do COPOM em todo o período de divulgação de atas . . . . .         | 51 |
| Figura 9 – Ranking de palavras mais usadas nos comunicados do COPOM após a adoção do câmbio flutuante . . . . .             | 52 |
| Figura 10 – Nuvem de palavras mais usadas nos comunicados do COPOM após a adoção do câmbio flutuante . . . . .              | 53 |
| Figura 11 – Ranking de modificadores mais usados nos comunicados do COPOM em todo o período de divulgação de atas . . . . . | 53 |
| Figura 12 – Variação da frequência de uso das 10 palavras mais mencionadas ao longo do tempo . . . . .                      | 54 |
| Figura 13 – Variação da frequência de uso das 10 palavras mais mencionadas ao longo do tempo . . . . .                      | 54 |
| Figura 14 – Comparação entre a SELIC de 1 ano efetiva e a SELIC de 1 ano prevista no boletim FOCUS . . . . .                | 56 |

|  |    |
|--|----|
| Figura 15 – Comparação entre a variação percentual do índice Ibovespa e o Índice de Sentimentos calculado com o modelo de tópico/modificador . . . | 56 |
| Figura 16 – Comparação entre a variação percentual do índice Ibovespa e o Índice de Sentimentos calculado com o modelo usando BERT . . . . .       | 57 |
| Figura 17 – Comparação entre a variação percentual do índice Ibovespa e o Índice de Sentimentos calculado com o modelo usando FinBERT-PT-BR .      | 58 |
| Figura 18 – Variação dos valores dos Índices de Sentimento obtidos ao longo do tempo . . . . .   | 60 |
| Figura 19 – Resposta ao impulso do modelo usando pares tópico/modificador . . . . .  | 61 |
| Figura 20 – Resposta ao impulso do modelo usando BERT . . . . .  | 62 |
| Figura 21 – Resposta ao impulso do modelo usando FinBERT-PT-BR . . .   | 63 |

## **Lista de tabelas**

|   |    |
|---|----|
| Tabela 1 – Relação de siglas e significados para substituição automática no texto .....                                       | 43 |
| Tabela 2 – Lista de palavras sem significado removidas da análise .....   | 44 |
| Tabela 3 – Comparação entre resultado da regressão linear entre os 3 modelos e a variação percentual do índice Ibovespa ..... | 58 |

## Lista de abreviaturas e siglas

|       |   |  |
|-------|---|--|
| AM    | - | Aprendizado de Máquina   |
| BACEN | - | Banco Central do Brasil  |
| BC    | - | Banco Central do Brasil  |
| BERT  | - | Transformadores de Representações de Codificadores Bidirecionais |
| BRL   | - | Real Brasileiro  |
| COPOM | - | Comitê de Política Monetária Brasileiro                          |
| DXY   | - | Índice de Variação do Dólar em Relação a Outras Moedas           |
| FED   | - | Banco Central Estadunidense                                      |
| FOMC  | - | Comitê de Política Monetária Estadounidense                      |
| IA    | - | Inteligência Artificial  |
| LLM   | - | Modelos grandes de linguagem                                     |
| MAE   | - | Erro Médio Absoluto  |
| ML    | - | <i>Machine Learning</i> : Aprendizado de Máquina                 |
| MSE   | - | Erro Quadrático Médio  |
| PLN   | - | Processamento de Linguagem Natural                               |
| NLP   | - | Processamento de Linguagem Natural                               |
| RLM   | - | Regressão Linear Múltipla  |
| RLS   | - | Regressão Linear Simples   |
| RMSE  | - | Raiz do Erro Quadrático Médio                                    |
| S&P   | - | Índice da Standard & Poor's                                      |
| SELIC | - | Sistema Especial de Liquidação e Custódia                        |
| SVM   | - | Máquinas de Vetores Suporte                                      |
| USD   | - | Dólar Americano  |
| VIX   | - | Índice de Volatilidade das ações estadounidenses                 |

# Sumário

|  |           |
|--|-----------|
| <b>Agradecimentos.....</b>   | <b>3</b>  |
| <b>Resumo.....</b>   | <b>4</b>  |
| <b>Sumário.....</b>  | <b>11</b> |
| <b>1. Introdução e Motivação.....</b>  | <b>13</b> |
| 1.1 A Influência da Macroeconomia no cotidiano.....                                | 13        |
| 1.2 A Era dos Dados.....   | 15        |
| 1.3 Objetivo.....  | 16        |
| 1.4 Organização.....   | 16        |
| <b>2. Inteligência Artificial.....</b>   | <b>17</b> |
| 2.1 Processamento de Linguagem Natural.....  | 18        |
| 2.2 Aprendizado de Máquina.....  | 19        |
| 2.3 Redes Neurais.....   | 20        |
| 2.3.1 Rede Neural com Aprendizado Supervisionado.....                              | 21        |
| 2.3.2 Rede Neural com Aprendizado Não Supervisionado.....                          | 22        |
| 2.3.3 Rede Neural com Aprendizado Por Reforço.....                                 | 22        |
| 2.4 Deep Learning.....   | 22        |
| 2.5 Análise de sentimento.....   | 24        |
| 2.5.1 Aplicação ao Índice de Sentimento dos Comunicados do<br>COPOM.....           | 25        |
| 2.6 Modelos grandes de linguagem.....  | 25        |
| 2.6.1 BERT.....  | 27        |
| 2.6.2 FinBERT-PT-BR.....   | 28        |
| <b>3. Apresentação Dos Dados Financeiros Numéricos E Textuais.....</b>             | <b>28</b> |
| 3.1 Dados Textuais: Comunicados do COPOM.....                                      | 29        |
| 3.2 Dados Financeiros Numéricos.....   | 30        |
| 3.2.1 Ibovespa.....  | 30        |
| 3.2.1.1 S&P 500.....   | 31        |
| 3.2.1.2 VIX.....   | 33        |
| 3.2.2 Par USD/BRL: Taxa de Câmbio.....   | 34        |
| 3.2.2.1 DXY: Índice de Comparação do Dólar Internacionalmente....                  | 35        |
| 3.2.3 Taxas de Juros.....  | 36        |
| 3.2.3.1 Juros Pré Fixados.....   | 37        |
| 3.2.3.2 Juros Pós Fixados: Taxa SELIC.....   | 38        |
| <b>4. Metodologia.....</b>   | <b>39</b> |
| 4.1 Séries Temporais.....  | 39        |
| 4.1.1 Período de Análise: Regime de Câmbio Flutuante.....                          | 40        |
| 4.1.2 Período de Análise: Primeiro dia útil após a divulgação do comunicado.<br>42 |           |
| 4.2 Tratamento dos Dados.....  | 42        |

|  |           |
|--|-----------|
| 4.2.1 Tratamento do texto.....                                     | 42        |
| 4.3 Algoritmo em Alto Nível.....                                   | 44        |
| 4.3.1 Modelo Utilizando Pares de Tópicos e Modificadores.....      | 45        |
| 4.3.1.1 Treinamento do Modelo.....                                 | 46        |
| 4.3.2 Modelo Utilizando BERT Original.....                         | 47        |
| 4.3.3 Modelo Utilizando FinBERT-PT-BR.....                         | 50        |
| <b>5. Análise Estatística Dos Comunicados.....</b>                 | <b>50</b> |
| 5.1 Palavras Mais Utilizadas nos Comunicados.....                  | 50        |
| 5.2 Frequência de Uso das Palavras Mais Utilizadas nos Comunicados | 54        |
| 5.3 Balizando Expectativas.....                                    | 55        |
| <b>6. Resultados E Testes Dos Modelos.....</b>                     | <b>56</b> |
| 6.1 Resultado dos Índices de Sentimento ao longo do tempo.....     | 60        |
| 6.2 Resposta ao Impulso dos Modelos.....                           | 61        |
| <b>7. Conclusão.....</b>   | <b>64</b> |
| <b>Referências.....</b>  | <b>67</b> |

# 1. Introdução e Motivação

Uma das ferramentas macroeconômicas mais utilizadas na atualidade para condução da Política Monetária é o *forward guidance*, implementado por meio dos comunicados divulgados pelos Bancos Centrais para sinalizar suas intenções futuras, ajudando a ajustar as expectativas econômicas e a reduzir a incerteza. Estudos como o realizado por Doh, Kim e Yang (2021) mostram que o tom qualitativo dos comunicados pode afetar significativamente os preços dos ativos.

Por outro lado, modelos de PLN são particularmente úteis na interpretação de grandes volumes de textos, inclusive econômicos. A aplicação de técnicas de aprendizado de máquina (ML) na avaliação desses comunicados para melhor compreensão do *forward guidance* destaca-se por sua capacidade de melhorar a precisão e a profundidade das análises, uma vez que esses modelos podem captar nuances e sentimentos implícitos que influenciam a percepção do mercado. Isso permite uma avaliação mais detalhada das expectativas econômicas e das reações subsequentes do mercado, oferecendo uma ferramenta complementar poderosa para a análise macroeconômica tradicional, conforme destacado por Doh, Kim e Yang (2021).

Por isso, foi realizada neste capítulo uma introdução sobre a influência da macroeconomia no cotidiano de todas as pessoas, utilizando como exemplo acontecimentos de grande repercussão no Brasil durante o período de análise, de modo a situar o tema em que está contido o objeto principal de estudo deste trabalho, que são as Atas das reuniões do Comitê de Política Monetária do Banco Central do Brasil.

Este trabalho conecta-se intimamente com a literatura existente sobre a condução econômica e política monetária, traçando um paralelo desde os primórdios do FED, o Banco Central dos Estados Unidos da América, até os dias atuais no Brasil, passando pelo efeito da condução econômica na Europa, e explorando a interseção entre macroeconomia e aprendizado de máquina.

## 1.1 A Influência da Macroeconomia no cotidiano

A influência da macroeconomia - especialmente da inflação, do PIB, do PIB per capita e das taxas de juros - sobre a vida das pessoas é muito relevante, influenciando hábitos de consumo, poupança, endividamento e investimento, mesmo quando essas pessoas não percebem ou não possuem conhecimento sobre economia (CHUNYA BU, JOHN ROGERS e WENBIN WU, 2019). Além disso, existe uma forte influência mútua entre estes dados macroeconômicos (MÁXIMO, 2022).

Também é parte do senso comum que uma condução econômica temerária por parte dos governantes, ou mesmo a simples percepção pública de que isso está ocorrendo, pode ter uma influência muito grande no comportamento da população em geral, levando a consequências de grandes proporções como revoltas populares, manifestações, e até um impedimento presidencial. Conforme destacado por Cirillo:

Em julho de 2013, uma intensa sequência de manifestações contrárias ao aumento de 20 centavos na tarifa do transporte

público municipal tomou as ruas da cidade de São Paulo. Apesar de sua ambição inicialmente regionalista, esta ação desencadeou uma sequência de eventos que fugiu por completo das capacidades de planejamento e controle de seus organizadores.

Ao longo do mês de julho deste mesmo ano, este fenômeno ultrapassou seu mote e seu regionalismo originais e atingiu grande parte das principais cidades do país, majoritariamente por conta da mobilização em redes sociais. Seus participantes, destituídos de pautas objetivas, passaram a clamar de maneira abstrata contra a corrupção e a ineficiência do Estado brasileiro. As críticas do movimento ao modelo petista de governar têm como alvo um Estado supostamente “colossal”, isto é, uma estrutura do setor público ampliada para intervir na economia em áreas onde o setor privado geraria soluções mais eficientes. Como consequência, este teria se tornado ineficiente e prejudicial ao bom funcionamento da economia. Geraria, ainda, uma arrecadação tributária cada vez maior, facilitando a apropriação indevida do erário público (CIRILLO, 2024: 01).

Segundo Cirillo (2024), esse acontecimento foi um dos fatores que desencadeou o impedimento presidencial ocorrido no Brasil em 2016

Outro exemplo é o impacto das políticas de austeridade na Grécia durante a crise financeira de 2008. De acordo com Krugman (2015), as medidas de austeridade impostas visavam reduzir o déficit público, mas resultaram em uma contração econômica severa e aumento do desemprego.

Estes dois casos ilustram como decisões de política econômica podem ter consequências profundas e muitas vezes adversas na economia real e na política em diferentes países.

Conforme analisado por Selzer (2020) acerca desta relação entre a economia e os fenômenos políticos, o Liberalismo tende a ocupar todos os espaços da sociedade:

Pelo Liberalismo ser uma ideologia "total", com uma visão definida de mundo em suas dezenas de variáveis, não pode abrir mão de construir um pensamento econômico e regular práticas econômicas. As variantes existem, mas cada uma dessas possui, pela natureza da construção do pensamento à que remete historicamente, um thelos econômico, uma pretensão de organização social, uma esquematização e interpretação generalizante e universal sobre o mundo e o homem, mas não só: sobre seus bens, propriedade e vida econômica.

Ao desenvolver o materialismo histórico dialético, Marx centraliza a discussão no campo econômico. Percebe a necessidade de se levar ad extremis a análise do funcionamento material da sociedade, por ser o fator determinante para o funcionamento de todas as outras esferas da vida (a conhecida análise superestrutural). Marx não só é propositivo como leva a necessidade de conjunção entre filosofia política e pensamento econômico às últimas consequências, advogando por ação política e ação econômica revolucionária.

A conexão entre filosofia política, a prática econômica e a economia real é, aqui, necessária e abrangente (2020: 21).

Assim, o Banco Central, independente ou não, tornou-se uma importante ferramenta no desenvolvimento econômico de um país, conforme projetado por Alexander Hamilton na promulgação da Lei que criou o Federal Reserve - o Banco Central dos Estados Unidos da América - aprovada no Congresso Americano em 1790 e sancionada pelo Presidente George Washington em 25 de Fevereiro de 1791 (RASMUS, 2020). Conforme dito também por Selzer:

Alexander Hamilton acreditava que o desenvolvimento de uma democracia sadia e de uma máquina pública capacitada para gerir pessoas e garantir a soberania nacional passava pela construção de um estado federal forte, centralizado. O principal instrumento da construção deste estado, projeto da vida de Hamilton, seria um sistema financeiro nacional, através da criação de um Banco Nacional e do estabelecimento de uma dívida pública. (SELZER, 2020: 74)

Portanto, é razoável considerar que, no Brasil, a condução da Política Monetária por parte do COPOM deve ser feita de maneira estratégica e orientada por evidências e objetivos claros, por ser considerada uma importante engrenagem dentro da Política Econômica desde sua concepção até os dias atuais, independentemente do espectro político, tendo grande poder de influência no cotidiano da população.

## **1.2 A Era dos Dados**

Ao mesmo tempo, o cenário tecnológico atual se caracteriza por uma enorme quantidade de dados produzidos por seres humanos e máquinas, bem como por um crescimento exponencial da capacidade de processamento. Esses dois fatores fazem com que a ciência de dados seja uma disciplina fundamental em vários domínios, conforme proposto Goodfellow, Bengio e Courville (2016), inclusive na economia, de forma a criar uma cultura de tomada de decisões macroeconômicas baseadas em dados, conforme proposto por Jagtap (2019).

Com a crescente quantidade de dados disponíveis, há boas razões para acreditar que a análise inteligente de dados se tornará cada vez mais

difundida como um componente necessário para o progresso tecnológico (RIOS E ROSA, 2022).

Além disso, nos últimos anos, os dados estão ganhando relevância em vários campos do conhecimento. Para isso, diversos modelos de análise de dados foram e ainda estão em desenvolvimento, como dito por Shalev-Shwartz e Ben-David (2014).

Nas últimas décadas, o Aprendizado de Máquina tornou-se um dos pilares da tecnologia da informação e, com isso, uma parte central, por destacar-se especialmente nos problemas muito complexos para abordagens tradicionais que não possuem um algoritmo conhecido, ou que tratem de uma grande quantidade de dados, conforme destacado por Rios e Rosa (2022).

Tal expediente permite a interpretação de grandes massas de dados, em certos casos até mesmo dados de milhões de indivíduos, o que propicia a obtenção de conclusões e decisões consistentes (GAO et al., 2019). A perspectiva de impacto na vida das pessoas é, desse modo, concreta (GUSMÃO, 2020).

### **1.3 Objetivo**

Sendo assim, uma possibilidade muito interessante é a de empregar ferramentas de aprendizado de máquina na mineração de dados econômicos, a fim de prever parte de seu comportamento futuro e seu efeito em outros ativos.

O objetivo principal deste trabalho é, portanto, realizar uma análise das variáveis macroeconômicas dos comunicados do COPOM, utilizando-se de modelos de aprendizado de máquina, com foco especial em análise textual, processamento de linguagem natural, análise de sentimento, modelagem preditiva com regressão linear para otimização de parâmetros e análise de séries temporais.

### **1.4 Organização**

Este trabalho está organizado da seguinte forma:

- Capítulo 2: Este capítulo abordará a definição de conceitos relacionados ao campo de estudos de Inteligência Artificial.
- Capítulo 3: Neste capítulo são apresentados os dados financeiros numéricos e textuais utilizados neste trabalho.
- Capítulo 4: Aborda-se neste capítulo a metodologia utilizada em cada um dos algoritmos de análise de sentimento analisados.
- Capítulo 5: Neste capítulo são apresentados estudos estatísticos feitos sobre os textos dos comunicados do COPOM.
- Capítulo 6: Os resultados e os testes realizados serão apresentados neste capítulo.
- Capítulo 7: Conclusão dos resultados obtidos e dos esperados.

## **2. Inteligência Artificial**

Inteligência artificial é um campo da ciência da computação que se dedica à criação de sistemas capazes de realizar tarefas que normalmente requerem inteligência humana, por meio do desenvolvimento de algoritmos e modelos matemáticos que permitem às máquinas aprender e adaptar-se com base em dados, permitindo-lhes melhorar seu desempenho ao longo do tempo. Há 3 tipos de inteligência artificial:

- IA Limitada, que refere-se a sistemas de IA projetados e treinados para realizar uma tarefa específica ou um conjunto restrito de tarefas, operando sob um conjunto limitado de restrições e sem capacidades gerais de resolução de problemas.
- IA de Propósito Geral, que refere-se a sistemas de IA que possuem capacidades cognitivas em nível humano, com habilidade de entender, aprender e aplicar conhecimentos de maneira geral, adaptando-se a uma ampla variedade de tarefas. Atualmente, é apenas teórica e ainda não foi alcançada na prática.
- IA Superinteligente, que refere-se a sistemas de IA que ultrapassam a inteligência humana em todos os aspectos, incluindo criatividade, resolução de problemas e tomada de decisões. Atualmente, também é apenas teórica e reflete uma visão futurista e especulativa da IA.

A categoria de IA Limitadas possui diversas subdivisões funcionais, cada uma especializada em diferentes aspectos e aplicações, as quais não serão citadas neste trabalho. Para o recorte deste trabalho, serão aprofundadas apenas as técnicas de LLM, que se encontra dentro da categoria das inteligências artificiais limitadas, e que consistem em modelos de *machine learning* que utilizam algoritmos de *deep learning* para processar e entender a linguagem natural.

## 2.1 Processamento de Linguagem Natural

Processamento de Linguagem Natural (NLP) é um subcampo crucial da inteligência artificial focado na interação entre computadores e linguagem humana. As técnicas de NLP são empregadas para permitir que as máquinas compreendam, interpretem e respondam a textos e falas de maneira significativa e útil. A complexidade do NLP reside na natureza ambígua e contextual da linguagem humana, que requer um entendimento profundo de sintaxe, semântica, pragmática e até mesmo do contexto cultural necessário para ser processada de forma eficaz.

O desenvolvimento do Processamento de Linguagem Natural (NLP) tem sido impulsionado pela necessidade de entender e processar a linguagem humana de maneira automatizada. Essas representações são essenciais para tarefas como tradução automática, resumo de textos e análise de sentimento, onde a semântica e o contexto são fundamentais.

As técnicas de NLP abrangem uma variedade de métodos, incluindo a tokenização, a análise sintática, o reconhecimento de entidades nomeadas e a modelagem semântica. A tokenização divide o texto em unidades menores, como palavras ou frases, facilitando a análise subsequente. A análise sintática, por sua vez, determina a estrutura gramatical das frases, enquanto o reconhecimento de entidades nomeadas identifica elementos chave, como nomes de pessoas, organizações e locais. A modelagem semântica busca capturar o significado das palavras e frases, permitindo uma compreensão mais profunda e contextual do texto.

Os modelos utilizam redes neurais profundas para aprender

representações contextuais de palavras, frases e textos inteiros a partir de grandes quantidades de dados de treinamento.

## 2.2 Aprendizado de Máquina

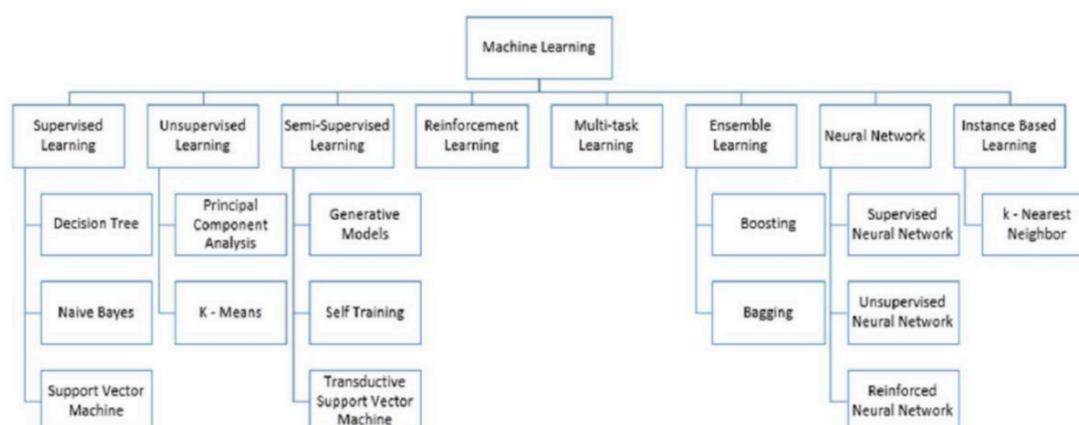
O aprendizado de máquina é um subcampo da inteligência artificial que se concentra no desenvolvimento de algoritmos que permitem aos computadores aprenderem a partir de dados. Esse aprendizado pode ocorrer de forma supervisionada, não supervisionada ou por reforço.

No aprendizado supervisionado, o modelo é treinado com um conjunto de dados rotulados, onde a saída correta é conhecida. Isso permite que o modelo aprenda a mapear entradas para saídas desejadas. Técnicas comuns incluem regressão linear, árvores de decisão e redes neurais.

No aprendizado não supervisionado, os dados de entrada não possuem rótulos e o modelo deve encontrar padrões e estruturas nos dados. Técnicas como clustering e redução de dimensionalidade são frequentemente utilizadas.

O aprendizado por reforço envolve treinar um agente para tomar decisões sequenciais a fim de maximizar uma recompensa acumulada.

Conforme destacado por Rios e Rosa (2022), o trabalho de Mahesh (2020) propõe definições para 8 grupos de modelos de Aprendizado de Máquina, que se dividem em 14 subgrupos, conforme mostrado na Figura 1:



Fonte: MAHESH, 2020.

As técnicas de Machine Learning (ML) utilizam computação avançada para desenvolver algoritmos capazes de identificar e interpretar padrões nos dados, permitindo que esses algoritmos sejam treinados para responder de maneira eficaz às entradas de informação. Com o treinamento contínuo, os modelos são aprimorados, o que resulta em um modelo estatístico que pode prever valores de variáveis de interesse com maior precisão, sensibilidade a erros e capacidade de adaptação a novas entradas.

Em essência, o aprendizado de máquina pode ser interpretado como uma aplicação computacional que gera previsões com base em propriedades conhecidas e aprendidas a partir de dados de treinamento, identificando padrões de acordo com Hastie, Tibshirani e Friedman (2009). Durante o processo de aprendizado, os parâmetros do modelo preditor são ajustados automaticamente para minimizar o erro de predição, melhorando a capacidade de generalização do modelo quando confrontado com novos dados.

Uma possível ameaça à generalização é o sobreajuste (*overfitting*), que ocorre quando o modelo se torna extremamente especializado no conjunto de dados de treinamento, resultando em baixo desempenho com novos dados. Por outro lado, o subajuste (*underfitting*) ocorre quando o algoritmo não se ajusta adequadamente aos padrões dos dados de treinamento, também resultando em desempenho insatisfatório, como discutido por Goodfellow, Bengio e Courville (2016). Técnicas como validação cruzada e regularização costumam ser empregadas para mitigar esses problemas.

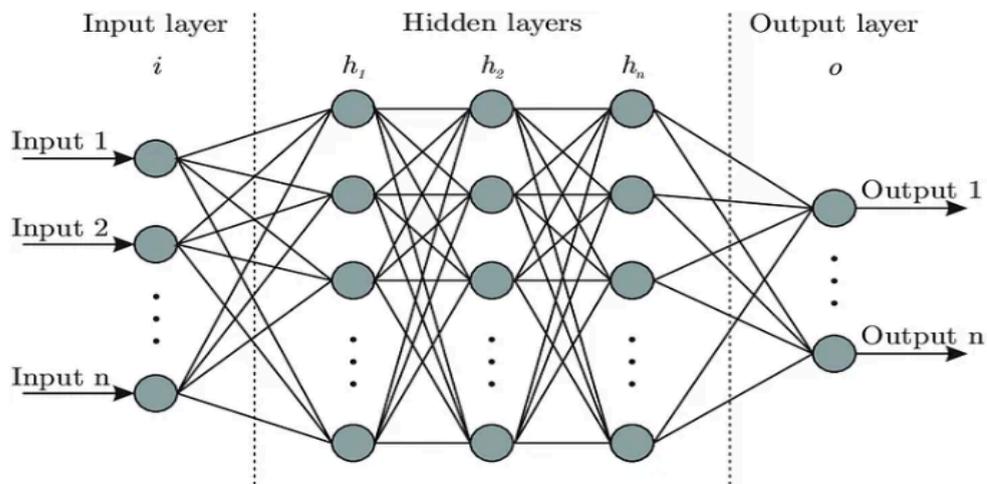
## **2.3 Redes Neurais**

Conforme proposto por Goodfellow, Bengio e Courville (2016), uma rede neural é composta por uma série de algoritmos projetados para reconhecer padrões e entender as relações subjacentes em um conjunto de dados, inspirando-se no funcionamento do cérebro humano. Em essência, redes neurais são sistemas compostos por neurônios, que podem ser biológicos (naturais) ou artificiais. As redes neurais são capazes de se adaptar às mudanças nas entradas, permitindo que gerem os melhores resultados possíveis sem a necessidade de redesenhar os critérios de saída.

As redes neurais artificiais normalmente são estruturadas em três camadas principais: a camada de entrada, a camada oculta e a camada de saída. A camada de entrada recebe os dados brutos, a camada oculta processa esses dados aplicando pesos e funções de ativação, e a camada de saída fornece a resposta calculada pela rede. Essa estrutura permite que as redes neurais realizem tarefas complexas de reconhecimento de padrões, classificação e predição.

As arquiteturas de redes neurais descrita acima costumam ser representadas conforme a Figura 2 abaixo:

Figura 2 – Arquitetura de Redes Neurais.



Fonte: Shukla, 2019.

### 2.3.1 Rede Neural com Aprendizado Supervisionado

Conforme proposto por [Goodfellow, Bengio e Courville, 2016], no aprendizado supervisionado os valores de referência (ou rótulos) são conhecidos. A saída prevista pela rede neural é comparada com a saída real, e, com base no erro calculado (função de perda), os parâmetros da rede (pesos e *bias*) são ajustados através de algoritmos como o *backpropagation* e a otimização por gradiente descendente.

Esse processo é repetido iterativamente até que a rede atinja um nível aceitável de precisão. As redes neurais supervisionadas são frequentemente utilizadas em arquiteturas de rede de alimentação direta (*feedforward neural networks*), amplamente aplicadas em problemas de classificação e

regressão.

### **2.3.2 Rede Neural com Aprendizado Não Supervisionado**

Conforme proposto por [Hinton e Salakhutdinov, 2006], no aprendizado não supervisionado, a rede neural não recebe rótulos de saída para as entradas. O principal objetivo da rede é identificar padrões e estruturar os dados em grupos (*clustering*) ou representar os dados de maneira mais eficiente (redução de dimensionalidade). Algoritmos como redes neurais de Kohonen (*Self-Organizing Maps*) e *autoencoders* são exemplos de técnicas de aprendizado não supervisionado. Esses métodos são valiosos para a exploração de dados e detecção de anomalias, onde os dados não são previamente rotulados.

### **2.3.3 Rede Neural com Aprendizado Por Reforço**

Conforme proposto por Sutton (2018), o aprendizado por reforço é uma abordagem orientada a objetivos, onde algoritmos aprendem a tomar decisões sequenciais para maximizar uma recompensa cumulativa ao longo do tempo.

Esse tipo de aprendizado é modelado como um problema de decisão de Markov (MDP), onde o agente interage com um ambiente e recebe feedbacks na forma de recompensas ou punições. Técnicas como *Q-learning* e métodos de política (*Policy Gradient*) são utilizados para treinar esses agentes. O aprendizado por reforço tem demonstrado grande sucesso em jogos e robótica, muitas vezes alcançando desempenho sobre-humano em tarefas complexas.

## **2.4 Deep Learning**

*Deep Learning*, ou aprendizado profundo, representa uma subárea do aprendizado de máquina que se baseia em redes neurais artificiais com múltiplas camadas, conhecidas como redes neurais profundas. Essas redes são projetadas para modelar e abstrair padrões em níveis hierárquicos, permitindo que o sistema aprenda representações complexas e

características de alto nível a partir de dados brutos. A profundidade da rede, ou seja, o número de camadas ocultas, permite que ela capture nuances sutis nos dados, tornando-a especialmente poderosa para tarefas como reconhecimento de imagens, processamento de linguagem natural e tradução automática (LECUN, BENGIO, & HINTON, 2015).

O avanço do *deep learning* foi significativamente impulsionado por três fatores principais: a disponibilidade de grandes volumes de dados, o aumento do poder computacional e as melhorias nas técnicas de treinamento de redes neurais. A utilização de unidades de processamento gráfico (GPUs) e, mais recentemente, de unidades de processamento tensorial (TPUs), permitiu a execução eficiente de cálculos complexos necessários para treinar redes profundas.

Além disso, técnicas como normalização por lotes (*batch normalization*), regularização por *dropout* e otimização por gradiente estocástico com *momentum* têm contribuído para a estabilização e aceleração do treinamento de redes profundas (LOFFE & SZEGEDY, 2015). Entre as arquiteturas mais proeminentes no campo do *deep learning* estão as redes convolucionais (CNNs) e as redes recorrentes (RNNs).

As CNNs são amplamente utilizadas em tarefas de visão computacional, onde a convolução local ajuda a extrair características espaciais importantes das imagens (KRICHEVSKY, SUTSKEVER, & HINTON, 2012).

Já as RNNs e suas variantes mais avançadas como as redes de memória de longo curto prazo (LSTM) e unidades recorrentes de porta (GRU) são especialmente eficazes para dados sequenciais, como séries temporais e texto, devido a sua capacidade de manter informações contextuais ao longo do tempo.

Esses avanços em *deep learning* não apenas ampliaram as fronteiras da inteligência artificial, mas também possibilitaram novas aplicações e melhorias em áreas antes inacessíveis (HOCHREITER & SCHMIDHUBER, 1997).

## 2.5 Análise de sentimento

A análise de sentimento, também conhecida como mineração de opiniões, é uma área do processamento de linguagem natural (NLP) que se dedica à identificação e à extração de informações subjetivas dos textos. O objetivo principal é determinar as atitudes, opiniões e emoções expressas por indivíduos em relação a determinados tópicos.

Esse campo de estudo tornou-se especialmente relevante com o crescimento das redes sociais e a vasta quantidade de dados textuais disponíveis online, permitindo a análise de opiniões em larga escala. A análise de sentimento pode ser aplicada em diversos contextos, incluindo análise de mercado, monitoramento de marca e feedback de clientes (PANG & LEE, 2008).

Existem diferentes abordagens para a análise de sentimento, que podem ser categorizadas em métodos baseados em léxicos e métodos baseados em aprendizado de máquina.

Os métodos baseados em léxicos utilizam dicionários de sentimentos, onde palavras são associadas a valores de polaridade (positivo, negativo ou neutro). Esses métodos são simples e rápidos, mas podem não capturar nuances contextuais e gírias.

Com o advento do *deep learning*, a análise de sentimento tem se beneficiado de técnicas avançadas que melhoram significativamente a precisão das classificações. Redes neurais profundas podem ser treinadas para entender contextos complexos e relacionamentos semânticos, proporcionando uma análise mais sofisticada e detalhada. Essas técnicas demonstram excelentes resultados na classificação de sentimentos em diversos domínios, como análises de discurso político.

No contexto da análise de sentimento, técnicas de Processamento de Linguagem Natural (NLP) são fundamentais. Elas permitem a extração de informações valiosas a partir dos textos, como as comunicações do COPOM, que são o objeto de estudo principal deste trabalho. Modelos de NLP são desenvolvidos para entender e classificar sentimentos com base em padrões linguísticos.

### **2.5.1 Aplicação ao Índice de Sentimento dos Comunicados do COPOM**

A análise de sentimento das comunicações do COPOM envolve a aplicação dessas técnicas de NLP para identificar e quantificar o sentimento expresso nos textos, conforme proposto em Ke, Kelly e Xiu (2019).

Utilizando modelos de ML baseados na arquitetura BERT, podemos obter representações precisas do conteúdo semântico dos comunicados, permitindo a construção de um índice de sentimentos robusto. Esse índice pode então ser usado para analisar tendências e padrões ao longo do tempo, fornecendo informações valiosas sobre o tom e a direção das políticas econômicas.

Além disso, a utilização de pares tópico/modificador ajuda a contextualizar o sentimento identificado, associando-o a tópicos específicos mencionados nos comunicados. Isso permite uma análise mais detalhada e segmentada, revelando como diferentes aspectos das políticas do COPOM são percebidos em termos de sentimento.

## **2.6 Modelos grandes de linguagem**

Os modelos grandes de linguagem (LLMs), como o ChatGPT da OpenAI, Bard e Gemini do Google, Copilot da Microsoft, entre outros, representam uma forma avançada de inteligência artificial, mas que ainda se enquadram na categoria de IA Limitada ou IA Fraca (*Narrow AI*).

Esse tipo de inteligência artificial é utilizado em tarefas específicas e projetado para processar e gerar linguagem natural, facilitando interações em linguagem humana com aplicações que vão desde assistentes virtuais até a criação de conteúdos textuais. Essas ferramentas operam com base em grandes quantidades de dados e modelos matemáticos para entender e produzir texto, mas não possuem compreensão ou consciência.

Dentre os modelos testados neste trabalho encontra-se o LLM BERT (*Bidirectional Encoder Representations from Transformers*), que é um modelo de linguagem desenvolvido pelo Google para entender o contexto de uma palavra com base em todas as palavras de sua vizinhança (à esquerda

e à direita). Também foi testado o LLM FinBERT-PT-BR, que é uma variação especializada de BERT, adaptada para aplicações no setor financeiro brasileiro.

Os modelos grandes de linguagem (LLMs) representam um marco significativo no campo da inteligência artificial e processamento de linguagem natural (NLP). Esses modelos são treinados em vastas bases de dados textuais, permitindo que aprendam nuances complexas e variadas da linguagem humana. O processo de treinamento envolve a exposição do modelo a bilhões de frases e sentenças, utilizando técnicas avançadas de aprendizado profundo para capturar as sutilezas do uso linguístico. A arquitetura subjacente desses modelos, muitas vezes baseada em *transformers*, facilita a modelagem de relações contextuais profundas e de longa distância entre palavras (VASWANI et al., 2017).

A eficácia dos LLMs é impulsionada pela sua capacidade de pré-treinamento em tarefas gerais de linguagem e subsequente ajuste fino em tarefas específicas. Este método, conhecido como transferência de aprendizado, permite que um modelo previamente treinado em uma ampla gama de textos seja adaptado para domínios específicos com uma quantidade menor de dados especializados.

A capacidade de transferir conhecimentos adquiridos durante o pré-treinamento para novas tarefas permite o uso de LLMs como ferramentas versáteis e poderosas. Um exemplo é o modelo GPT-4, desenvolvido pela OpenAI para atividades como compreensão e geração de textos, tradução automática, resposta a perguntas, entre outras aplicações, que possui tal versatilidade devido ao seu treinamento em um conjunto diversificado de textos da internet (BROWN et al., 2020).

Entretanto, os LLMs não estão isentos de desafios. Um dos principais problemas é o viés presente nos dados de treinamento, que pode ser refletido nos *outputs* gerados pelos modelos. Além disso, a complexidade e opacidade desses modelos tornam difícil a interpretação acerca de como atingiram determinadas conclusões, levantando preocupações sobre a transparência e as justificativas.

Pesquisas contínuas estão sendo realizadas para mitigar esses problemas, incluindo a utilização de técnicas como o ajuste de pesos e a implementação de mecanismos de supervisão para controlar e reduzir o viés (BENDER et al., 2021). Apesar desses desafios, os avanços nos LLMs continuam a expandir o horizonte de possibilidades no campo da IA e do NLP, proporcionando ferramentas poderosas para uma ampla gama de aplicações práticas.

### **2.6.1 BERT**

BERT (*Bidirectional Encoder Representations from Transformers*) é um modelo de linguagem desenvolvido pelo Google que revolucionou o campo do Processamento de Linguagem Natural (NLP). Introduzido por Devlin *et al.* (2019), BERT é baseado na arquitetura de *transformers* e foi projetado para entender o contexto completo de uma palavra em uma frase, considerando tanto as palavras à esquerda quanto à direita (bidirecionalidade). Essa capacidade de capturar o contexto bidirecional permite que BERT compreenda nuances complexas e relações semânticas profundas em textos, superando limitações de modelos anteriores que analisam o texto de forma unidirecional (DEVLIN et al., 2019).

O treinamento de BERT envolve duas etapas principais: pré-treinamento e ajuste fino. Durante o pré-treinamento, BERT é treinado em grandes bases de textos utilizando duas tarefas principais: modelagem de linguagem mascarada (MLM) e predição da próxima sentença (NSP). Na tarefa de MLM, algumas palavras em uma sequência são mascaradas aleatoriamente e o modelo é treinado para prever essas palavras com base no contexto fornecido pelas palavras circundantes. Na tarefa de NSP, o modelo aprende a prever se uma frase é a continuação lógica da frase anterior. Após o pré-treinamento, BERT pode ser ajustado (*fine-tuned*) em tarefas específicas, como classificação de texto, resposta a perguntas e análise de sentimento, utilizando conjuntos de dados menores e específicos para essas tarefas (DEVLIN et al., 2019).

## 2.6.2 FinBERT-PT-BR

FinBERT-PT-BR é uma variação do BERT adaptada especificamente para o setor financeiro, a partir de textos da área escritos na língua portuguesa do Brasil.

O FinBERT foi inicialmente desenvolvido para aplicações em inglês, focando na análise de textos financeiros, como relatórios de mercado, notícias econômicas e comunicados corporativos (SANTOS, BIANCHI e COSTA, 2023). A adaptação para o português do Brasil (FinBERT-PT-BR) envolve um processo de ajuste fino onde o modelo pré-treinado é ajustado em conjuntos de dados específicos do setor financeiro em português, incluindo documentos de mercados financeiros brasileiros, análises de investimentos e relatórios econômicos. Essa adaptação permite que FinBERT-PT-BR capture melhor as nuances e os jargões específicos do setor financeiro brasileiro, oferecendo maior precisão e relevância na análise de textos financeiros em português (SANTOS, BIANCHI e COSTA, 2023).

A capacidade de BERT e suas variações, como FinBERT-PT-BR, de capturar contextos complexos e fornecer *insights* precisos em domínios específicos, tem ampliado significativamente as aplicações de NLP em diversos setores. Estes modelos são particularmente valiosos para tarefas que exigem compreensão profunda de contexto e linguagem, permitindo avanços notáveis em áreas como análise de sentimento, classificação de documentos e resposta a perguntas, transformando a maneira como interagimos com dados textuais (SUN et al., 2019).

## 3. Apresentação Dos Dados Financeiros Numéricos E Textuais

Neste trabalho foram usadas duas fontes principais de informações: os Comunicados Oficiais do COPOM, especificamente as atas das reuniões do Comitê, em formato textual, e os valores de mercado de determinados ativos e índices acionários, de câmbio ou de juros, em formato numérico.

### **3.1 Dados Textuais: Comunicados do COPOM**

O Comitê de Política Monetária (COPOM) do Banco Central do Brasil é responsável por formular a política monetária do país, com o objetivo de assegurar a estabilidade de preços. As comunicações oficiais do COPOM, especialmente as atas das reuniões, desempenham um papel crucial no mercado financeiro brasileiro.

Estas atas, divulgadas periodicamente, detalham as discussões e decisões do Comitê sobre a taxa básica de juros (SELIC), além de fornecerem uma visão sobre as perspectivas econômicas e os fatores que influenciam a política monetária.

As atas das reuniões do COPOM são instrumentos essenciais de comunicação com o mercado, promovendo transparência e previsibilidade nas ações do Banco Central. Elas contêm análises detalhadas sobre a economia nacional e internacional, inflação, atividade econômica e sobre as condições do mercado de crédito, entre outros fatores. De acordo com Ribeiro e Costa, "as atas do COPOM fornecem informações valiosas que ajudam os agentes econômicos a formar expectativas sobre a futura trajetória da política monetária" (2018: 45).

A influência das atas do COPOM no mercado financeiro brasileiro é significativa. As informações contidas nas atas podem impactar diretamente a taxa de câmbio, os preços de ativos financeiros e a curva de juros futuros. A antecipação das decisões do COPOM pode levar a movimentos especulativos no mercado, afetando a volatilidade e a liquidez.

Além disso, as atas desempenham um papel crucial na ancoragem das expectativas de inflação, conforme analisado por Doh, Kim e Yang (2021). Quando o COPOM comunica claramente suas avaliações e intenções, contribui para reduzir a incerteza no mercado, o que é essencial para a eficácia da política monetária. Como destacam Ferreira e Santos, "a clareza e a consistência das comunicações do COPOM são fundamentais para a ancoragem das expectativas inflacionárias e para a credibilidade do Banco Central" (2020: 98).

A incerteza em torno das perspectivas econômicas pode ainda levar a uma política monetária mais cautelosa, caso o Banco Central atue como

gestor de risco e responda sistematicamente às flutuações na incerteza, conforme destacado por Duarte (2020).

A influência das atas do COPOM se estende também à política fiscal e à percepção de risco soberano. As decisões de política monetária, refletidas nas atas, podem afetar a percepção dos investidores sobre a sustentabilidade fiscal e a estabilidade econômica do país. Por exemplo, durante períodos de alta inflação ou crises econômicas, a comunicação do COPOM pode influenciar as avaliações de risco e o custo de captação do governo no mercado internacional.

Em resumo, as atas das reuniões do COPOM são instrumentos fundamentais na comunicação da política monetária no Brasil. Elas influenciam diretamente o mercado financeiro, ajudando a formar expectativas e a ancorar a inflação, além de impactar a percepção de risco e a política fiscal. A clareza e a transparência dessas comunicações são essenciais para a eficácia da política monetária e para a credibilidade do Banco Central do Brasil.

## **3.2 Dados Financeiros Numéricos**

Para este trabalho foram usados dados financeiros públicos para analisar os diversos ativos relacionados à economia brasileira, bem como dados relacionados ao mercado acionário e de câmbio dos Estados Unidos, que podem influenciar o mercado interno.

Os dados do índice de ações Ibovespa, do índice de ações S&P 500, do índice de volatilidade VIX, do câmbio entre Real Brasileiro e Dólar Americano USD/BRL e do índice do Dólar Americano DXY foram obtidos da plataforma pública Yahoo finanças (2024). Os dados de juros pré e pós fixados do Brasil foram obtidos do site do Tesouro Direto (2024).

### **3.2.1 Ibovespa**

O Índice Bovespa (Ibovespa) é o principal indicador de desempenho das ações negociadas na Bolsa de Valores de São Paulo (B3). Criado em 1968, o Ibovespa é um índice de retorno total que considera tanto a valorização

das ações quanto os dividendos pagos pelas empresas que compõem sua carteira. O índice é calculado com base em uma média ponderada dos preços das ações das empresas mais negociadas e representativas do mercado acionário brasileiro, proporcionando um termômetro do comportamento do mercado de ações no Brasil (SIQUEIRA, 2007).

O Ibovespa serve como referência para diversos tipos de investimentos e é utilizado como *benchmark* por gestores de fundos, analistas e investidores individuais. O desempenho do Ibovespa é frequentemente associado ao cenário econômico e político do país, refletindo a confiança dos investidores na estabilidade econômica e na governança corporativa das empresas listadas. Além disso, as variações no índice podem influenciar as decisões de investimento e alocação de recursos, tanto no mercado doméstico quanto no mercado internacional (GARCIA & COSTA JR., 2015).

A relação entre o Ibovespa e o Comitê de Política Monetária (COPOM) do Banco Central do Brasil é um aspecto crucial para a compreensão das dinâmicas do mercado financeiro brasileiro. O COPOM é responsável por definir a taxa básica de juros (SELIC), que é um dos principais instrumentos de política monetária no Brasil. As decisões do COPOM sobre a Selic têm um impacto direto no custo do crédito e na atratividade dos investimentos em renda fixa, influenciando, assim, o fluxo de capitais para o mercado de ações.

Quando o COPOM decide reduzir a Selic o custo do crédito diminui, estimulando o consumo e o investimento, o que geralmente resulta em uma valorização do Ibovespa. Por outro lado, aumentos na Selic tendem a tornar os investimentos em renda fixa mais atraentes, podendo levar a uma migração de recursos do mercado de ações para o mercado de renda fixa, dessa forma impactando negativamente o Ibovespa (MENDONÇA, 2009).

### **3.2.1.1 S&P 500**

O índice S&P 500 é um dos principais indicadores do desempenho do mercado de ações dos Estados Unidos, composto pelas 500 maiores empresas listadas nas bolsas de valores de Nova York (NYSE) e Nasdaq. Criado pela Standard & Poor's, o S&P 500 é amplamente utilizado como um

indicador para o mercado de ações norte-americano e global, representando aproximadamente 80% da capitalização de mercado total do mercado acionário dos EUA.

Em um mundo onde os mercados estão cada vez mais integrados, o desempenho do S&P 500 pode ter efeitos profundos sobre as economias emergentes, incluindo o Brasil. Quando o S&P 500 se valoriza, isso geralmente indica uma confiança crescente dos investidores na economia dos EUA, o que pode também aumentar a confiança nos mercados emergentes. Essa dinâmica foi estudada por Castro e Lima, que observam que "movimentos no S&P 500 frequentemente precedem fluxos de capital estrangeiro para o Brasil, influenciando diretamente a bolsa de valores brasileira" (2020: 112).

Além disso, o S&P 500 serve como um termômetro para o apetite ao risco dos investidores globais. Em períodos de alta no índice, há uma maior disposição para investimentos em mercados emergentes, enquanto quedas no S&P 500 podem provocar retiradas de capital e aumento na aversão ao risco. Esta correlação foi analisada por Martins e Sousa, que concluíram que "a volatilidade do S&P 500 tem um impacto direto na volatilidade do mercado financeiro brasileiro, demonstrando a sensibilidade da B3 às flutuações do mercado norte-americano" (2019: 87).

A influência do S&P 500 vai além do mercado financeiro brasileiro, tendo implicações significativas no mercado financeiro mundial. Como indicador chave da saúde econômica dos Estados Unidos, que é a maior economia do mundo, o S&P 500 é monitorado de perto por investidores globais. Flutuações no índice podem sinalizar mudanças nas perspectivas econômicas globais, afetando decisões de investimento em todos os continentes. De acordo com Silva e Pereira, "o S&P 500 atua como um barômetro global, onde sua performance pode antecipar tendências econômicas que impactam mercados em diversas regiões, incluindo Europa, Ásia e América Latina" (2021: 145).

Portanto, a relevância do S&P 500 no mercado financeiro não pode ser subestimada. Sua influência se estende além das fronteiras dos Estados Unidos, afetando diretamente mercados emergentes como o Brasil e

desempenhando um papel crucial na formação de expectativas econômicas globais. Para investidores e formuladores de políticas econômicas, compreender as dinâmicas do S&P 500 é essencial para navegar no complexo cenário econômico mundial.

### **3.2.1.2 VIX**

O Índice de Volatilidade (VIX), também conhecido como o "índice do medo", é uma medida da expectativa do mercado sobre a volatilidade futura dos preços das ações no S&P 500. Calculado pela *Chicago Board Options Exchange* (CBOE), o VIX é amplamente utilizado como um indicador de risco e incerteza no mercado financeiro. Valores elevados do VIX geralmente indicam um aumento na percepção de risco entre os investidores, enquanto valores baixos sugerem um ambiente de mercado mais calmo e previsível.

A influência do VIX no mercado financeiro brasileiro é notável. Como indicador de volatilidade e medo, o VIX tende a afetar diretamente o comportamento dos investidores em mercados emergentes, incluindo o Brasil. Em momentos de alta volatilidade no VIX, os investidores frequentemente reagem reduzindo sua exposição a ativos de risco, como ações de mercados emergentes, e buscando segurança em ativos mais estáveis, como títulos do governo dos EUA. Essa dinâmica foi analisada por Lima e Barbosa, que observaram que "oscilações no VIX têm um impacto direto nos fluxos de capital para o Brasil, afetando a liquidez e os preços dos ativos na B3" (2018: 78).

Além disso, o VIX exerce uma influência significativa sobre as políticas de investimento e a alocação de ativos. Durante períodos de alta volatilidade, os gestores de portfólios tendem a adotar estratégias mais conservadoras, ajustando suas carteiras para mitigar riscos. Essa relação foi destacada por Souza e Almeida, que afirmam que "o aumento do VIX leva a uma reavaliação das estratégias de investimento, com uma tendência maior para a diversificação e a busca por ativos de refúgio" (2019: 103).

No cenário global, o VIX é um termômetro essencial para medir a aversão ao risco dos investidores. Sua influência se estende a diversos mercados financeiros ao redor do mundo, impactando desde as bolsas de

valores na Europa até os mercados de commodities na Ásia. Segundo Ferreira e Santos, "o VIX não apenas reflete a volatilidade esperada nos EUA, mas também serve como um indicador global de risco, afetando as decisões de investimento em diferentes regiões" (2020: 56).

A importância do VIX vai além de ser um mero indicador de volatilidade; ele é uma ferramenta crucial para a gestão de risco. Gestores de fundos e analistas de mercado utilizam o VIX para prever movimentos de mercado e ajustar suas estratégias de acordo. Por exemplo, durante crises financeiras, como a de 2008, o VIX atingiu níveis historicamente altos, sinalizando um período de extrema incerteza e aversão ao risco. Esse fenômeno foi detalhado por Castro e Lima, que explicam que "os picos no VIX durante crises financeiras servem como alertas para os investidores ajustarem suas posições e adotarem medidas de proteção" (2021: 89).

Em suma, o VIX desempenha um papel fundamental no mercado financeiro, tanto no Brasil quanto mundialmente. Sua capacidade de refletir a percepção de risco e incerteza o transforma em uma ferramenta indispensável para investidores e formuladores de políticas. Entender a dinâmica do VIX e suas implicações pode fornecer *insights* valiosos para navegar em períodos de volatilidade e incerteza no mercado financeiro global.

### **3.2.2 Par USD/BRL: Taxa de Câmbio**

A taxa de câmbio USD/BRL é uma medida que expressa o valor do dólar americano em relação ao real brasileiro. Essa taxa é determinada pela oferta e demanda de dólares no mercado de câmbio brasileiro e tem um papel crucial na economia do país. Ela afeta diretamente as importações, exportações, inflação e investimentos estrangeiros, sendo um indicador-chave da saúde econômica do Brasil (OLIVEIRA, 2018).

A importância do par USD/BRL vai além das transações comerciais. Ele também influencia o mercado financeiro brasileiro, em particular o Ibovespa, principal índice de ações da Bolsa de Valores de São Paulo. Mudanças na taxa de câmbio podem afetar a competitividade das empresas brasileiras, especialmente aquelas com operações internacionais. Uma desvalorização

do real em relação ao dólar pode beneficiar empresas exportadoras e impulsionar o desempenho do Ibovespa, enquanto uma valorização do real pode ter o efeito oposto (PEREIRA, 2015).

Além disso, a taxa de câmbio USD/BRL também está relacionada às decisões de política monetária do Banco Central do Brasil, representado pelo COPOM. Mudanças na taxa básica de juros, a Selic, podem influenciar a taxa de câmbio, pois afetam a entrada e saída de capital estrangeiro do país. Decisões do COPOM de aumentar ou diminuir a Selic podem impactar diretamente a taxa de câmbio, o que, por sua vez, pode afetar o desempenho do mercado de ações (CRESPO & FERREIRA, 2018).

### **3.2.2.1 DXY: Índice de Comparação do Dólar Internacionalmente**

O Índice de Comparação do Dólar Internacionalmente (DXY) é uma métrica amplamente utilizada para avaliar o desempenho do dólar americano em relação a uma cesta de moedas estrangeiras. Comumente composta por euro, iene japonês, libra esterlina, dólar canadense, coroa sueca e franco suíço, essa cesta representa os principais parceiros comerciais dos Estados Unidos. A variação do DXY reflete mudanças na força do dólar em relação a essas moedas, sendo considerado um indicador-chave para os investidores e analistas financeiros.

No contexto brasileiro, o DXY desempenha um papel significativo devido à sua influência no mercado financeiro. O Brasil é uma economia fortemente vinculada ao comércio internacional, e o dólar é uma moeda de referência crucial em muitas transações comerciais e financeiras. Portanto, flutuações no valor do dólar, refletidas no DXY, geram implicações diretas para a economia brasileira.

Uma das maneiras pelas quais o DXY afeta o mercado financeiro brasileiro é através de seu impacto nas taxas de câmbio. Quando o DXY se valoriza, o real tende a se depreciar em relação ao dólar, tornando as exportações brasileiras mais competitivas no mercado internacional. Por outro lado, uma queda no DXY pode levar a uma valorização do real, o que pode prejudicar a competitividade das exportações brasileiras.

As variações no DXY têm um impacto significativo nas exportações brasileiras, afetando os fluxos de comércio e a balança comercial do país. Um estudo realizado por Souza e Almeida observa que "a valorização do dólar, refletida pelo aumento do DXY, pode ser tanto uma bênção quanto uma maldição para a economia brasileira, dependendo das condições econômicas globais e das políticas internas" (2019).

Outro aspecto importante a considerar é o fenômeno da exportação de inflação, que está intimamente relacionado às flutuações do DXY. Quando o dólar se fortalece, os preços de importação tendem a cair, o que pode reduzir a pressão inflacionária em economias como a brasileira, que dependem significativamente de importações. No entanto, essa dinâmica pode variar dependendo de vários fatores, incluindo a elasticidade-preço das importações e a resposta da política monetária.

Em suma, o DXY desempenha um papel crucial no mercado financeiro brasileiro, muitas vezes sobrepondo a importância de dados internos. Sua influência nas taxas de câmbio e na dinâmica de preços tem repercussões significativas para as exportações brasileiras e para a estabilidade econômica do país. Portanto, entender as nuances dessa relação e sua interação com outros fatores é essencial para os formuladores de políticas e os participantes do mercado.

### **3.2.3 Taxas de Juros**

As taxas de juros são os principais instrumentos de política monetária utilizados pelos Bancos Centrais para influenciar a atividade econômica, com intuito de estimular o crédito ou frear a inflação por meio do desestímulo ao crédito, pois representam o custo do dinheiro ao longo do tempo, o que desempenha um papel crucial na tomada de decisões de investimento e consumo por parte de indivíduos, empresas e governos.

Conforme detalhado no Relatório de Inflação de Junho de 1999 pelo Banco Central:

Há na economia vários tipos de taxas de juros: taxas de poupança, taxas de empréstimo, taxas de financiamento etc. Além disso, elas diferem de acordo com o prazo, sendo classificadas como de curto, médio e longo prazos. Na verdade, apesar das várias taxas

existentes, o Banco Central controla diretamente apenas a taxa de juros do mercado de reservas bancárias. É nesse mercado específico, e pouco conhecido pela população, que ele pratica a política monetária e influencia as demais taxas da economia. Contudo, são as taxas de juros vigentes no sistema financeiro, em particular no sistema bancário, como taxas de aplicações financeiras, de empréstimo e de financiamento, que são relevantes para a população. Elas dependem também de fatores fora do controle do Banco Central, como margens de lucro, risco de crédito e expectativas quanto ao desempenho futuro da economia. Mais ainda, esse controle torna-se cada vez mais limitado à medida em que o prazo das taxas se amplia (BANCO CENTRAL, 1999).

Conforme detalhado no Relatório de Inflação de Junho de 1999, divulgado pelo Banco Central (IBIDEM), o valor da taxa de um dia é determinado pelo Banco Central, por meio da taxa SELIC, e os demais prazos de juros são determinados pela oferta e demanda por Títulos do Tesouro.

Além disso, a simples expectativa de mudança já é suficiente para causar efeitos econômicos, e este é o objeto de estudo deste trabalho, ou seja, analisar essa expectativa que será gerada pelo conteúdo do comunicado do COPOM. Especificamente, foram analisadas as atas das reuniões, e foi analisado o efeito dessa expectativa nos títulos com prazo de um ano, anualizada numa base de 252 dias úteis.

As taxas de juros podem ser categorizadas entre: juros pré-fixados e juros pós-fixados.

### **3.2.3.1 Juros Pré Fixados**

Os juros pré-fixados são aqueles cujo valor é estabelecido no momento da contratação e permanece constante até o vencimento. A SELIC é a taxa básica de juros da economia brasileira, definida pelo Comitê de Política Monetária (COPOM) do Banco Central do Brasil. Ela serve como referência para diversas operações financeiras e de crédito no país.

A Taxa SELIC é utilizada como ferramenta principal na condução da política monetária, sendo ajustada periodicamente para controlar a inflação. A taxa de juros influencia diretamente o nível de atividade econômica,

afetando tanto a demanda agregada quanto as expectativas de inflação. Quando a inflação está acima da meta estabelecida, o COPOM tende a elevar a SELIC para conter a demanda e reduzir as pressões inflacionárias. Inversamente, quando a inflação está abaixo da meta, a SELIC pode ser reduzida para estimular a economia.

A literatura econômica, como discutido por Mishkin (2015), destaca que a eficácia da política monetária depende da credibilidade do banco central. Uma política monetária crível, que ajusta a taxa SELIC de forma transparente e consistente com os objetivos de controle da inflação, contribui para a ancoragem das expectativas inflacionárias, facilitando o controle efetivo da inflação sem provocar volatilidade excessiva nos mercados financeiros.

### **3.2.3.2 Juros Pós Fixados: Taxa SELIC**

Os juros pós-fixados, por outro lado, são aqueles cujo valor é ajustado periodicamente com base em um índice de referência, que pode variar ao longo do tempo. No Brasil, um dos índices mais utilizados para contratos de juros pós-fixados é a própria Taxa SELIC ou o CDI (Certificado de Depósito Interbancário), que acompanha de perto a SELIC.

Os juros pós-fixados oferecem uma proteção contra a inflação e a volatilidade econômica, uma vez que são reajustados de acordo com as variações de um índice de referência. Esse tipo de taxa é particularmente vantajoso em ambientes de alta incerteza inflacionária ou quando se espera que as taxas de juros aumentem no futuro. A escolha entre juros pré-fixados e pós-fixados depende das expectativas dos investidores sobre a trajetória futura das taxas de juros e da inflação.

Os títulos públicos pós-fixados, como as Letras Financeiras do Tesouro (LFTs), são exemplos comuns de instrumentos que utilizam juros pós-fixados. Esses títulos são populares entre investidores que buscam proteção contra a inflação e desejam uma remuneração que reflita as condições econômicas vigentes.

Em resumo, as taxas de juros, sejam elas pré-fixadas ou pós-fixadas, desempenham um papel essencial na economia, influenciando as decisões

de consumo, investimento e poupança, além de serem instrumentos chave na condução da política monetária. A compreensão das dinâmicas das taxas de juros é fundamental para a análise econômica e a formulação de estratégias financeiras eficazes.

## **4. Metodologia**

Este capítulo tem como objetivo introduzir a base teórica subjacente ao desenvolvimento do modelo de predição, bem como os conceitos e métodos empregados e discutidos neste estudo. Inicialmente, é importante citar as características centrais da análise baseada em séries temporais e, posteriormente, a utilização de algoritmos de aprendizado de máquina aplicados a essas séries, culminando em uma visão geral da aplicação dessas técnicas na modelagem de um índice de sentimentos para os comunicados do COPOM.

### **4.1 Séries Temporais**

Uma série temporal é definida como um conjunto de observações sequenciais ao longo do tempo, onde a dependência entre observações vizinhas é uma característica central. É crucial considerar essa ordem temporal ao analisar os dados, pois a correlação entre os pontos de dados sucessivos pode revelar padrões comportamentais importantes.

As séries temporais podem ser compostas por componentes como tendência, sazonalidade, ciclicidade e ruído. A tendência representa o movimento de longo prazo nos dados, a sazonalidade captura os padrões recorrentes em intervalos regulares, a ciclicidade refere-se a flutuações não sazonais de longo prazo, e o ruído é a variação aleatória inexplicável nos dados.

A representação gráfica dos dados temporais é fundamental, pois pode destacar padrões de comportamento que são críticos para a análise. Idealmente, um gráfico temporal deve preceder qualquer análise detalhada para fornecer uma visão inicial sobre a estrutura dos dados. Métodos como

gráficos de linha, histogramas e autocorrelações são usados para visualizar séries temporais.

Grande parte dos dados observados empiricamente tem natureza temporal, fazendo da previsão de séries temporais uma área de significativa importância nas ciências e tecnologias. Para abordar este aspecto, introduzimos o referencial teórico do aprendizado de máquina diretamente ligado à previsão de séries temporais.

O estudo das séries temporais tem múltiplas finalidades. Neste trabalho, ele teve como foco na análise do sentimento presente nas comunicações do COPOM, utilizando técnicas de aprendizado de máquina para modelar um índice de sentimentos. A análise de séries temporais permite entender padrões passados para projetar tendências futuras, oferecendo *insights* valiosos para a tomada de decisões informadas no contexto econômico e financeiro.

#### **4.1.1 Período de Análise: Regime de Câmbio Flutuante**

O regime de câmbio flutuante, adotado pelo Brasil em janeiro de 1999, representa um sistema no qual a taxa de câmbio é determinada pelo mercado, ou seja, pela oferta e demanda de moedas estrangeiras. Esse regime contrasta com o regime de câmbio fixo, onde o valor da moeda é atrelado a outra moeda ou a uma cesta de moedas, sendo ajustado conforme necessário por meio de intervenções do Banco Central.

Realizar o filtro do período de análise a partir do regime de câmbio flutuante é essencial para estudos econômicos por várias razões. Primeiro, a transição para o câmbio flutuante marca uma mudança estrutural na forma como a economia reage a choques externos e internos. No regime de câmbio fixo, as autoridades monetárias intervêm regularmente para manter a taxa de câmbio estável, o que pode mascarar a verdadeira dinâmica do mercado cambial e dos fundamentos econômicos. Em contraste, no regime de câmbio flutuante, a taxa de câmbio reflete mais fielmente as forças do mercado, permitindo uma análise mais precisa da economia.

Esse ajuste automático é crucial para a análise econômica, pois influencia diretamente a competitividade das exportações, o custo das

importações, e, conseqüentemente, o saldo da balança comercial. Além disso, a volatilidade da taxa de câmbio sob um regime flutuante pode fornecer *insights* sobre a percepção do mercado em relação à saúde econômica do país.

Outro aspecto importante é que o regime de câmbio flutuante afeta significativamente a política monetária. Sob um regime de câmbio fixo, a capacidade do Banco Central de ajustar a taxa de juros é limitada pela necessidade de manter a paridade cambial. No entanto, com o câmbio flutuante, o Banco Central tem mais autonomia para utilizar a política monetária como uma ferramenta para controlar a inflação e estabilizar a economia. Ter a liberdade de ajustar sua própria política monetária é um dos principais benefícios do câmbio flutuante, para responder a choques econômicos.

Além disso, a análise de dados econômicos sob o regime de câmbio flutuante é fundamental para estudos de longo prazo sobre a inflação, crescimento econômico e estabilidade financeira. Desde a adoção do câmbio flutuante, o Brasil passou por várias crises econômicas e financeiras, e a taxa de câmbio desempenhou um papel central na absorção desses choques. Portanto, ao filtrar o período de análise a partir de 1999, os pesquisadores podem obter uma visão mais clara das tendências econômicas e das políticas que foram implementadas em resposta a esses eventos.

O filtro do período de análise também permite uma comparação mais precisa com outros países que adotaram regimes de câmbio flutuante. Estudos comparativos podem revelar como diferentes economias respondem a choques similares sob um regime de câmbio flutuante, fornecendo lições valiosas para a formulação de políticas econômicas.

Em suma, realizar o filtro do período de análise a partir do regime de câmbio flutuante é crucial para obter uma compreensão precisa e significativa da dinâmica econômica no Brasil. Este regime proporciona uma visão mais transparente das forças do mercado, oferece maior flexibilidade para a política monetária, e permite análises comparativas robustas. Assim,

ele é essencial para estudos que visam entender a complexa interação entre a taxa de câmbio, política monetária, e o desempenho econômico.

#### **4.1.2 Período de Análise: Primeiro dia útil após a divulgação do comunicado**

Para evitar a contaminação dos dados com ruídos não relacionados ao comunicado em si, como divulgação de outros dados macroeconômicos, o período de análise foi restringido apenas ao efeito no primeiro dia útil após a divulgação do comunicado, tornando o tempo de análise discreto.

### **4.2 Tratamento dos Dados**

Em qualquer trabalho de análise de dados não estruturados, como os comunicados do COPOM em formato de texto e os dados financeiros vindos de origens variadas e em formatos variados, há uma etapa de menor brilho, porém necessária, de grande importância e onde é despendido a maior parte do tempo produtivo, que é a etapa de tratamento dos dados,

Durante essa etapa, são feitas as conversões de formato de datas, entre outras correções de tipagem de dados necessárias, como converter os dados todos para o mesmo formato, tipo e tamanho vetorial.

#### **4.2.1 Tratamento do texto**

Inicialmente foi realizada a substituição das siglas mais comuns do comunicado por seus significados, conforme mostrado na tabela 1 abaixo:

Tabela 1 – Relação de siglas e significados para substituição automática no texto.

| Sigla    | Significado  |
|----------|--|
| BCB      | Banco Central do Brasil                              |
| BNDES    | Banco Nacional de Desenvolvimento Econômico e Social |
| CDI      | Certificado de Depósito Interbancário                |
| CDS      | Credit Default Swap                                  |
| CNI      | Confederação Nacional da Indústria                   |
| COPOM    | Comitê de Política Monetária                         |
| FED      | Federal Reserve System                               |
| FMI      | Fundo Monetário Internacional                        |
| IA       | Índice de Atividade                                  |
| IBOVESPA | Índice da Bolsa de Valores de São Paulo              |
| IFP      | Inflação Futura Projetada                            |
| IGP-M    | Índice Geral de Preços do Mercado                    |
| IIE-Br   | Índice de Incerteza da Economia                      |
| IPCA     | Índice Nacional de Preços ao Consumidor Amplo        |
| MF       | Ministério da Fazenda                                |
| OMC      | Organização Mundial do Comércio                      |
| PEA      | População Economicamente Ativa                       |
| PIB      | Produto Interno Bruto                                |
| PNAD     | Pesquisa Nacional por Amostra de Domicílios          |
| POMC     | Plano de Operações do Mercado Aberto                 |
| ROE      | Retorno sobre o Patrimônio Líquido                   |
| SELIC    | Sistema Especial de Liquidação e de Custódia         |

Fonte: Elaboração própria.

Depois, são removidos caracteres desnecessários do texto, por exemplo símbolos especiais como “&”, “\$”, “#” entre outros, assim como “enter” e pontuações.

Também é feita a conversão das palavras para letras minúsculas, conversão das palavras para seus radicais no infinitivo, conversão de sinônimos em um mesmo radical e conversão das palavras para o singular.

Por fim, também é feita a remoção de *stopwords*, que são palavras do texto que não possuem significado e existem apenas para fazer interligações entre as palavras com significados, ou para fazer referência a aspectos burocráticos da reunião, como preposições ou onde a reunião ocorreu e quais os participantes. A lista completa de *stopwords* foi feita com base na

lista em inglês feita por Gardner, Scotti e Vega (2021), adaptando-a para o português do Brasil, e incluindo palavras observadas na análise de uso de palavras feita no capítulo 5, conforme mostrado na Tabela 2 abaixo:

Tabela 2: Lista de palavras sem significado removidas da análise.

| Lista de Palavras sem significado Removidas do Texto |           |          |           |              |           |
|--|-----------|----------|-----------|--------------|-----------|
| a  | dezembro  | índice   | nos       | primeira     | término   |
| à  | dia       | início   | nós       | primeiro     | trimestre |
| abril  | disso     | já       | nossa     | quadrimestre | última    |
| agosto   | do        | janeiro  | nosso     | qual         | um        |
| ainda  | dos       | julho    | novembro  | quando       | vai       |
| além   | doze      | junho    | o         | quarto       | vez       |
| andar  | e         | lado     | oitavo    | que          | vou       |
| ano  | é         | maio     | onde      | relação      | -         |
| ao   | ela       | mais     | os        | reunião      | -         |
| as   | elas      | março    | ou        | sala         | -         |
| chefes   | ele       | mas      | outro     | se           | -         |
| com  | eles      | membros  | outros    | segundo      | -         |
| comitê   | em        | mês      | outubro   | ser          | -         |
| como   | então     | meses    | para      | setembro     | -         |
| copom  | entre     | mesmo    | pelo      | sobre        | -         |
| da   | executiva | meu      | período   | sua          | -         |
| das  | fevereiro | minha    | por       | também       | -         |
| de   | gerência  | na       | porque    | tem          | -         |
| departamento   | há        | nacional | porquê    | temos        | -         |
| desde  | horário   | no       | presentes | terceiro     | -         |

Fonte: Elaboração Própria.

### 4.3 Algoritmo em Alto Nível

Para esse trabalho, foram usados três diferentes tipos de algoritmos de processamento de linguagem natural e de análise de sentimento, sendo um deles feito com um modelo léxico e dois deles utilizando LLMs. Nos 3 modelos, a otimização dos parâmetros foi feita usando regressão linear, para comparação dos resultados por meio do erro quadrático médio e do coeficiente de determinação.

Além disso, todos os modelos consistem na representação do texto em espaços vetoriais próprios, com atribuição de pesos para cada vetor utilizado, os quais são modificados iterativamente até que a média dos vetores ponderados pelos pesos esteja correlacionada com a variação diária

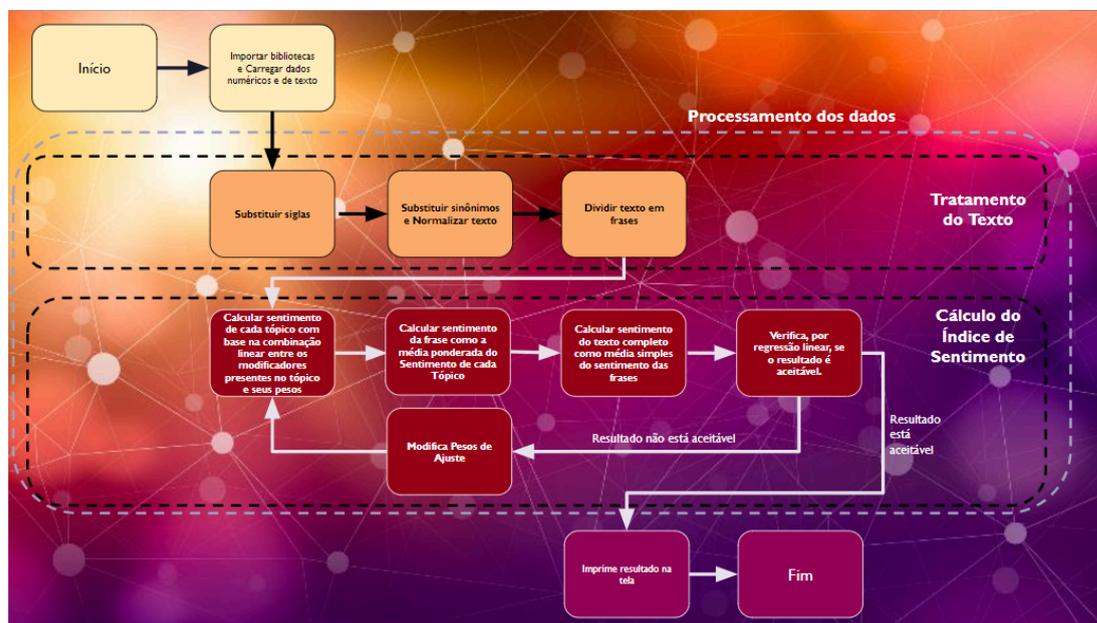
do Índice Ibovespa nos dias posteriores às divulgações dos comunicados.

### 4.3.1 Modelo Utilizando Pares de Tópicos e Modificadores

Modelos que utilizam pares tópico/modificador são frequentemente empregados para análise de sentimento. Esses modelos identificam tópicos relevantes dentro de um texto e, em seguida, determinam o sentimento associado com base nos modificadores (adjetivos, advérbios) que descrevem e “modificam” esses tópicos. Esse método é eficaz na captura de nuances de linguagem e na contextualização dos sentimentos expressos, conforme destacado por Alfieri, Eratalay, Lapitskaya e Sharma (2022).

Para definição de tópicos e de modificadores foi utilizado o dicionário proposto por Loughran e McDonald (2011). Foi feita a implementação de um modelo deste tipo para a finalidade conforme proposto por Gardner, Scotti e Vega (2021), utilizando o algoritmo descrito conforme Figura 3 abaixo:

Figura 3: Fluxograma do Algoritmo de Tópico/Modificador em Alto Nível, Elaboração própria.



Fonte: Elaboração Própria.

Os tópicos de destaque, definidos para serem acompanhados na análise são: “trabalho”, “produção”, “inflação”, “condições financeiras” e “política monetária futura”, bem como seus sinônimos. As palavras escolhidas como

modificador são: “melhoria”, “crescimento”, “deterioração”, “estável” e “possibilidade”, bem como seus sinônimos.

Para cada modificador, foi atribuído um peso diferente em cada tópico, de forma que um mesmo modificador por ser considerado positivo ou negativo, a depender do contexto e do tópico em que está sendo utilizado. O modificador “crescimento”, por exemplo, está associado a um peso negativo quando estamos tratando do tópico de “inflação”, e positivo quando estamos tratando do tópico de “produção”.

Desta forma, o valor obtido para o índice de sentimentos pode ser descrito matematicamente por:

$$\textit{Sentimento do Comunicado} = \frac{\sum \textit{Sentimento das frases}}{\sum \textit{Frases}}$$

$$\textit{Sentimento das Frases} = \frac{\sum \textit{Sentimento dos Tópicos}}{\sum \textit{Tópicos}}$$

$$\textit{Sentimento dos Tópicos} = \frac{\sum (\textit{peso do modificador} \times \textit{número de repetições do modificador na frase})}{\sum \textit{Modificadores}}$$

Para inicialização do algoritmo, todos os pesos foram inicializados com pesos iguais a “0”, “0.5”, “-0.5”, “1” ou “-1”, e o índice de sentimento foi calculado.

#### 4.3.1.1 Treinamento do Modelo

Para realizar o treinamento do modelo, foi utilizado como valor de comparação o valor da variação percentual diária do índice Ibovespa no primeiro dia útil após a divulgação do comunicado, para comparar com o resultado obtido para o índice de sentimentos.

A otimização do modelo é feita por meio de regressão linear, modificando os pesos atribuídos aos modificadores, e recalculando o valor obtido para o índice de sentimentos, em um processo iterativo, conforme descrito no fluxograma da Figura 3 acima.

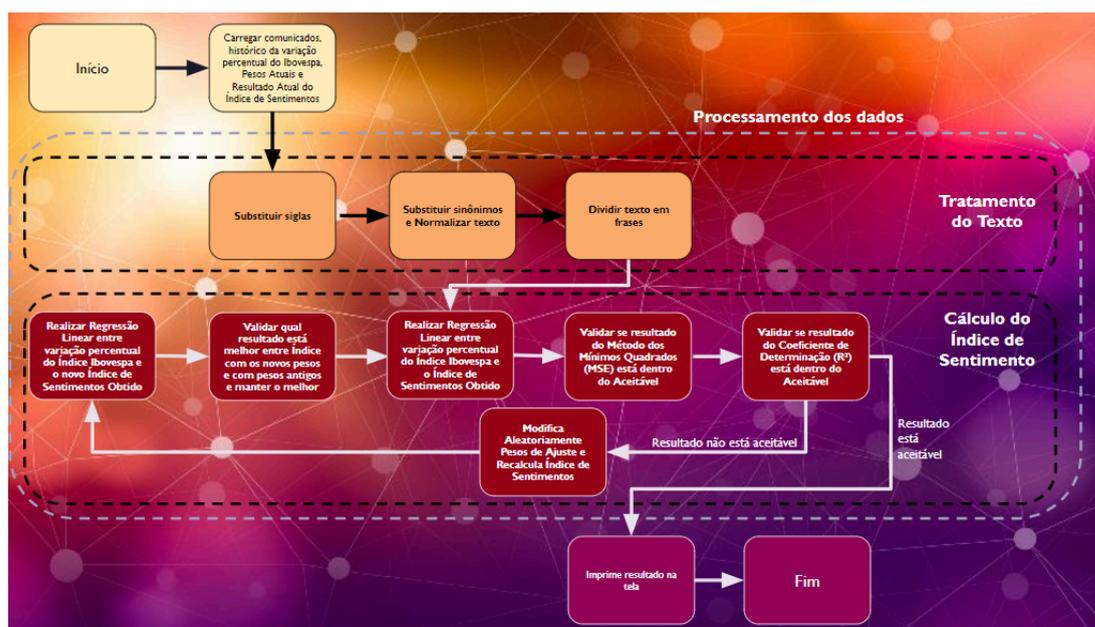
Esse procedimento, embora não envolva redes neurais complexas ou modelos de *deep learning*, pode ser considerado uma forma de inteligência artificial conforme classificado Mahesh (2020). Especificamente dentro do campo de aprendizado de máquina supervisionado e de séries temporais, onde o modelo é ajustado para melhorar a correspondência entre variáveis

independentes (índice de sentimento) e dependentes (variação do Ibovespa), sendo ambas funções do tempo e analisadas em tempo discreto.

O objetivo do algoritmo de otimização é minimizar a diferença entre o índice de sentimento calculado e a variação percentual do Ibovespa, medida por meio do erro quadrático médio (*Mean Squared Error*, MSE), e maximizar o coeficiente de determinação ( $R^2$ ).

Em cada iteração de treinamento, os pesos das palavras-chave e modificadores são ajustados aleatoriamente dentro de uma faixa específica. O índice de sentimento é recalculado com os novos pesos, e a diferença em relação à variação do Ibovespa é recalculada. Se o MSE for reduzido, os novos pesos são armazenados como os melhores encontrados, conforme descrito no fluxograma da Figura 4 abaixo:

Figura 4: Fluxograma do Algoritmo de treinamento para o Tópico/Modificador.



Fonte: Elaboração própria.

#### 4.3.2 Modelo Utilizando BERT Original

Recentemente, modelos baseados na arquitetura BERT (*Bidirectional Encoder Representations from Transformers*), que foi criada pelo Google, têm mostrado grande eficácia na análise de sentimento. BERT é um modelo pré-treinado em grandes massas de dados em formato de texto que utiliza uma arquitetura de *transformers*, permitindo uma compreensão bidirecional

do contexto. O modelo BERT é uma rede neural que utiliza a técnica de *deep learning* para compreender o contexto de palavras em uma sentença. Isso significa que BERT considera tanto o contexto à esquerda quanto à direita de uma palavra, proporcionando uma representação mais rica e precisa do significado e sentimento do texto (DEVLIN et al., 2019).

Por isso, o segundo modelo utiliza a técnica de *embeddings* BERT (*Bidirectional Encoder Representations from Transformers*). Este método envolve uma série de etapas, desde a tokenização do texto até a otimização dos pesos para encontrar a correlação ideal entre o índice de sentimento e a variação percentual do índice Ibovespa.

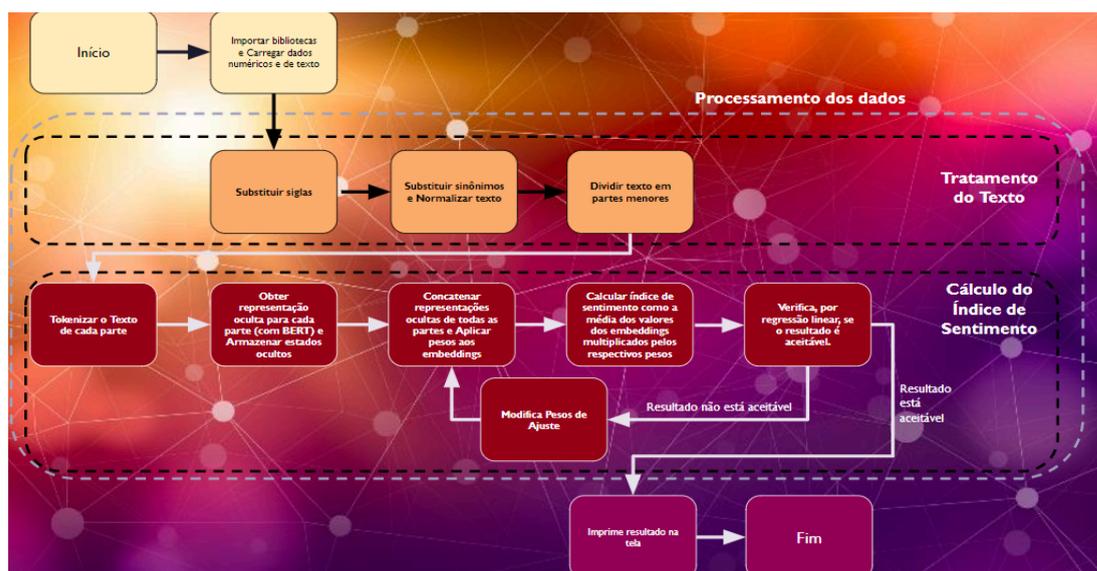
Inicialmente, o modelo divide o texto em partes menores devido às limitações do modelo BERT, que suporta até 512 *tokens* por entrada. As partes *tokenizadas* são então processadas pelo modelo BERT, e as representações ocultas (*embeddings*) das palavras são obtidas.

Para calcular o índice de sentimento, são utilizados pesos que ponderam os *embeddings* das palavras. Estes pesos são otimizados de forma a maximizar a correlação entre o índice de sentimento calculado e a variação percentual do Ibovespa, o que é feito iterativamente com diferentes conjuntos de pesos. A cada iteração, o algoritmo ajusta os pesos de forma a melhorar a correlação entre o índice de sentimento e a variação do Ibovespa. O objetivo é encontrar os pesos que maximizam essa correlação.

Após a otimização dos pesos, o algoritmo recalcula os índices de sentimento para os comunicados do COPOM utilizando esses pesos otimizados.

Este algoritmo combina processamento de linguagem natural (NLP) com técnicas de aprendizado de máquina para extrair *insights* dos comunicados do COPOM e correlacioná-los com o comportamento do mercado financeiro, conforme descrito no fluxograma da Figura 5 abaixo.

Figura 5: Fluxograma do Algoritmo para cálculo do índice de sentimentos usando BERT em Alto Nível.



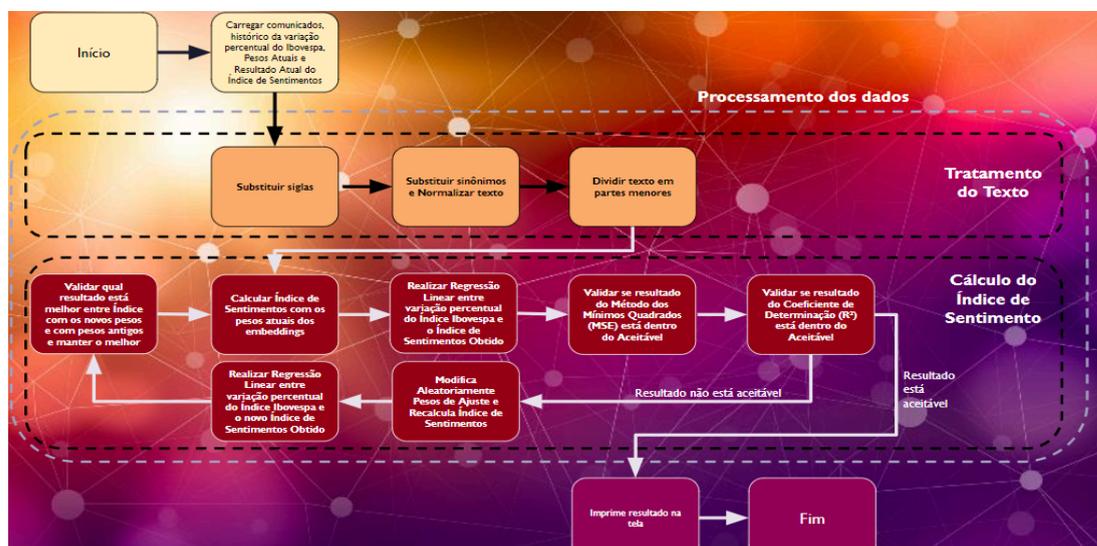
Fonte: Elaboração própria.

#### 4.3.1.2 Treinamento do Modelo

Para realizar o treinamento do modelo, novamente o valor da variação percentual do Ibovespa no primeiro dia útil após a divulgação foi utilizado como comparação para o resultado obtido para o índice de sentimentos.

A otimização do modelo também é feita por meio de regressão linear, modificando os pesos atribuídos aos tokens do espaço vetorial dos *embeddings* do BERT, e recalculando o valor obtido para o índice de sentimentos, em um processo iterativo, conforme descrito na Figura 6.

Figura 6: Fluxograma do Algoritmo de treinamento usando BERT em Alto Nível.



Fonte: Elaboração própria.

### **4.3.3 Modelo Utilizando FinBERT-PT-BR**

FinBERT-PT-BR trata-se de um modelo especializado de BERT, que foi pré-treinado no contexto do mercado financeiro em português do Brasil por Santos, Bianchi e Costa (2023), demonstrando a relação entre o índice de sentimentos gerado e o índice de inflação medida pelo IPCA.

Por se tratar de um BERT, a descrição técnica do funcionamento desse modelo e de seu treinamento é muito parecida com a anterior, alterando-se apenas a biblioteca utilizada para o modelo correto e os pesos finais obtidos para os *embeddings* ao final do treinamento do modelo. Mas é importante destacar que o treinamento original do modelo previa apenas a necessidade de realizar uma análise binária, analisando se o texto é positivo ou negativo, o que seria equivalente à comparação com a direção do movimento do Índice Ibovespa, sem considerar a magnitude.

## **5. Análise Estatística Dos Comunicados**

Analisando estatisticamente os documentos, é possível observar que a quantidade de menções de algumas palavras se destaca. Também é possível observar pequenas diferenças nas preocupações debatidas na reunião ao longo do tempo, refletindo em variações na frequência de uso dessas mesmas palavras de destaque.

### **5.1 Palavras Mais Utilizadas nos Comunicados**

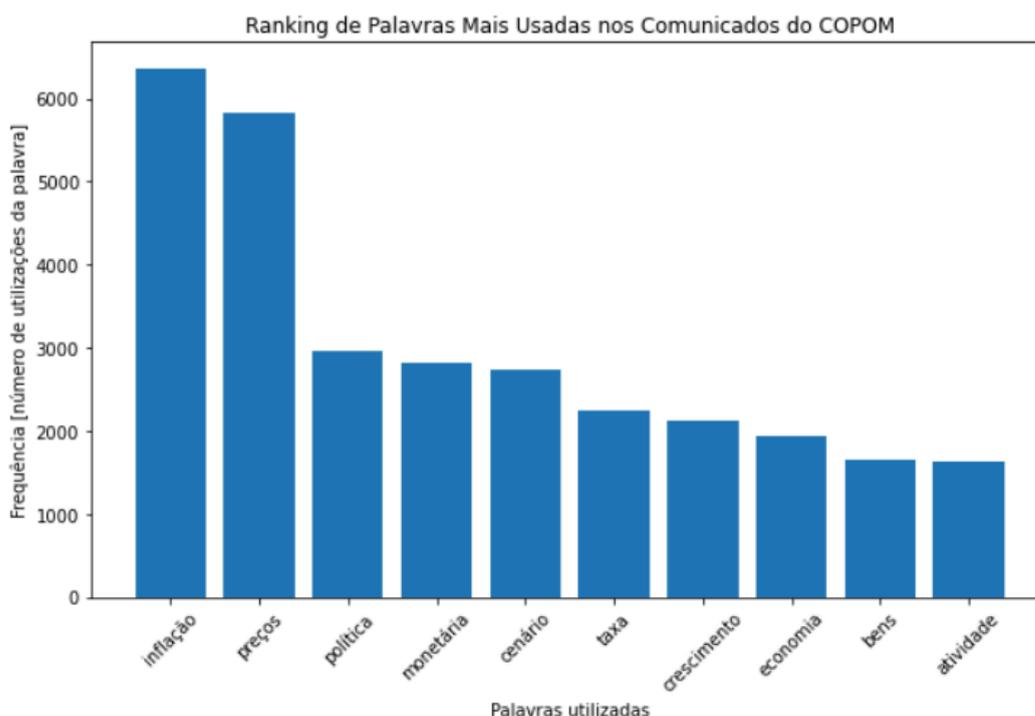
Analisando todo o período em que foram disponibilizados comunicados pelo COPOM, isto é, à partir da 21ª reunião, realizada em 28 de Janeiro de 1998 e divulgada em 22 de Maio de 1998, pode-se observar uma grande preocupação com os temas “inflação” e “preços”. Isto era previsível para a época, temas os quais destacam-se mesmo em relação a outras das 10 palavras mais utilizadas nos comunicados, conforme observa-se na Figura 7 abaixo:



Fonte: Elaboração própria.

Analisando apenas o período em que o Brasil adotou um regime de câmbio flutuante, dia 18 de Janeiro de 1999, data em que foi realizada a 32ª reunião do COPOM, divulgada em 21 de Maio de 1999, é possível observar que a preocupação com os temas “inflação” e “preços” se mantém, mas tiveram sua importância relativa diminuída, dentro das 10 palavras mais utilizadas nos comunicados no período. Além disso, também nota-se uma substituição da palavra “produção” pela palavra “atividade”, bem como uma diminuição da importância relativa da palavra “taxa”, deslocando-se da quarta para a sexta posição, conforme observa-se na Figura 9 abaixo:

Figura 9: Ranking de palavras mais usadas nos comunicados do COPOM após a adoção do câmbio flutuante.



Fonte: Elaboração Própria.

Novamente, é possível utilizar uma nuvem de palavras, conforme Figura 10 abaixo, para observar outras palavras que foram muito mencionadas nas atas das reuniões do COPOM no período, mostrando algumas mudanças de importância relativa entre as palavras, mas deixando claro que os temas debatidos, portanto também os termos utilizados, permanecem similares:

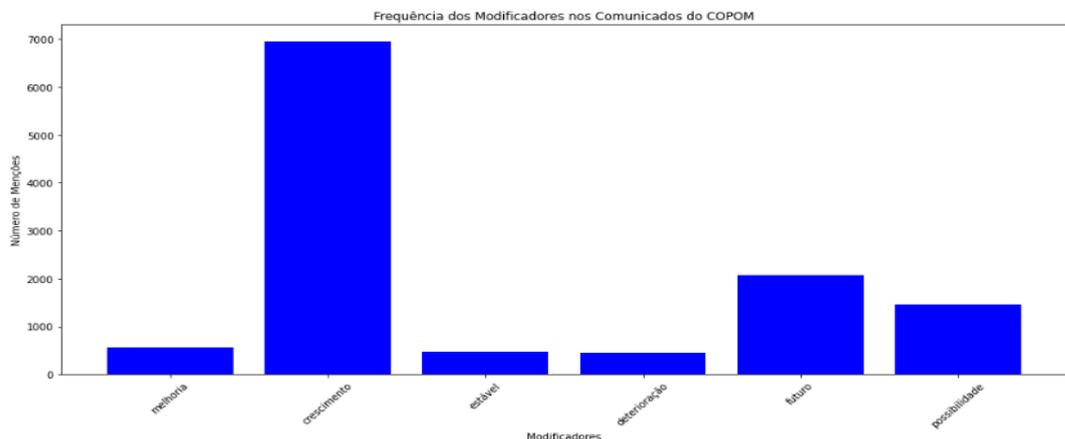
Figura 10: Nuvem de palavras mais usadas nos comunicados do COPOM após a adoção do câmbio flutuante.



Fonte: Elaboração Própria.

Se a análise de palavras for restrita para apenas as palavras presentes na lista de modificadores utilizadas no modelo de pares tópico/modificador, pode-se verificar na Figura 11 que o modificador mais utilizado foi “crescimento”, por ser um modificador que pode ser utilizado tanto em contextos positivos como “crescimento da produção” ou “crescimento do PIB” quanto em contextos negativos como “crescimento da inflação” ou “crescimento do desemprego”. Em segundo e terceiro lugar, aparecem os modificadores de incerteza futura “futuro” e “possibilidade”, indicando dúvidas quanto ao desempenho futuro da economia.

Figura 11: Ranking de modificadores mais usados nos comunicados do COPOM em todo o período de divulgação de atas.

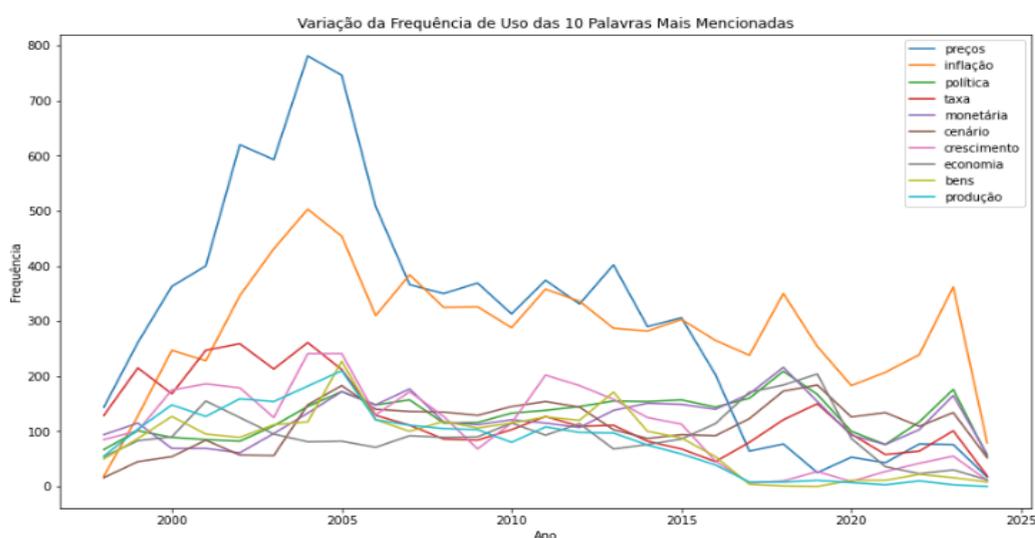


Fonte: Elaboração Própria.

## 5.2 Frequência de Uso das Palavras Mais Utilizadas nos Comunicados

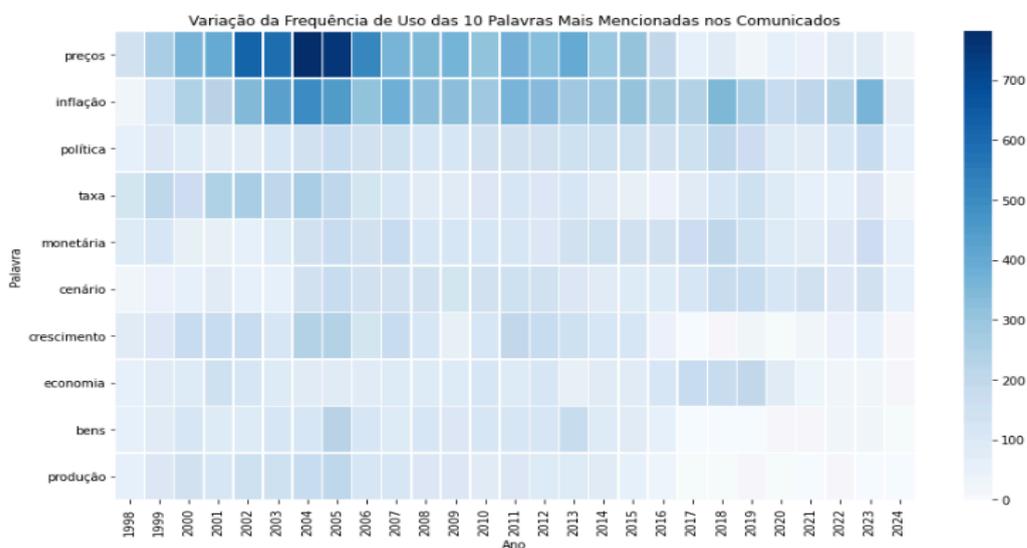
Outra forma interessante de analisar a variação das importâncias relativas de determinados temas, é por analisando a frequência de uso dessas palavras nos comunicados meio de um gráfico de linhas, ou de um gráfico de calor, conforme Figura 12 e Figura 13 abaixo:

Figura 12: Variação da frequência de uso das 10 palavras mais mencionadas ao longo do tempo.



Fonte: Elaboração Própria.

Figura 13: Variação da frequência de uso das 10 palavras mais mencionadas ao longo do tempo.



Fonte: Elaboração Própria.

Esses resultados evidenciam a diminuição da importância relativa da preocupação com a inflação nas reuniões do COPOM no período, sendo que a palavra “preços” deixou de integrar uma posição entre as duas palavras mais mencionadas desde 2017, e a palavra “inflação” também teve sua importância relativa bastante reduzida, dando lugar a termos como “política”, “economia” e “cenário”.

Os gráficos também evidenciam a influência que os acontecimentos políticos do país têm na pauta das reuniões do COPOM, sendo possível observar picos no uso das palavras mais usadas em determinados momentos específicos, como as manifestações de julho de 2013, eleições, pandemia e greve dos caminhoneiros, demonstrando a próxima relação entre a política, a economia, e a vida cotidiana das pessoas, conforme detalhado na introdução.

### **5.3 Balizando Expectativas**

Também é possível comparar as previsões da taxa SELIC divulgadas semanalmente a partir de 2006 no boletim Focus, que coleta a opinião dos agentes econômicos por meio de uma pesquisa, e a taxa SELIC anualizada efetiva, com uma base de 252 dias por ano.

E a comparação gráfica, conforme mostrado na Figura 14 abaixo, evidencia que os agentes antecipam os movimentos de juros que serão realizados pela autoridade monetária com base em suas comunicações. Em outras palavras, é possível perceber que a autoridade monetária realiza um balizamento das expectativas do mercado, por meio dos comunicados, apenas ratificando as decisões posteriormente, tornando as decisões mais transparentes.

Figura 14: Comparação entre a SELIC de 1 ano efetiva e a SELIC de 1 ano prevista no boletim FOCUS.

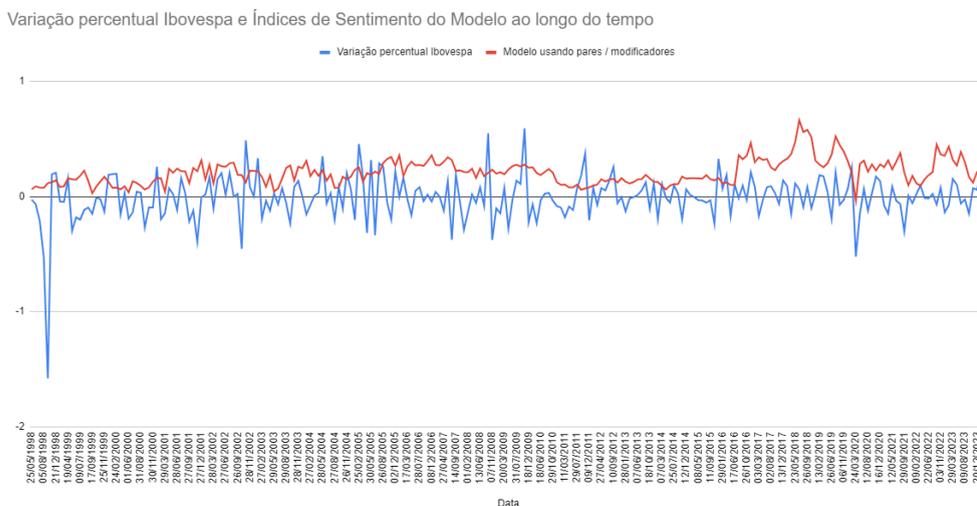


Fonte: Elaboração Própria.

## 6. Resultados E Testes Dos Modelos

Conforme Figura 15 abaixo, onde a variação percentual do Ibovespa foi multiplicada por 10, para melhor visualização, observou-se que o Índice de Sentimentos utilizando o modelo de pares tópico/modificador não está relacionado à variação percentual diária do Índice Ibovespa.

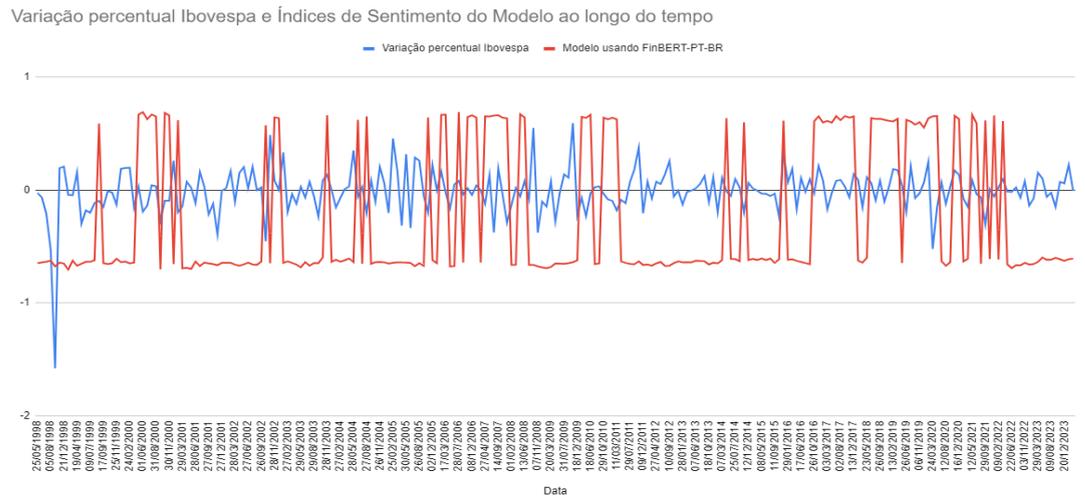
Figura 15: Comparação entre a variação percentual do índice Ibovespa e o Índice de Sentimentos calculado com o modelo de tópico/modificador.



Fonte: Elaboração Própria.



Figura 17: Comparação entre a variação percentual do índice Ibovespa e o Índice de Sentimentos calculado com o modelo usando FinBERT-PT-BR.



Fonte: Elaboração própria.

A comparação dos resultados obtidos por cada modelo foi feita por meio de regressão linear. Para realizá-la, foi utilizada a data como variável de tempo, a variação percentual do índice Ibovespa como variável dependente, e o resultado obtido para o índice de sentimentos com esse modelo como variável independente, conforme Tabela 3 abaixo:

Tabela 3: Comparação entre resultado da regressão linear entre os 3 modelos e a variação percentual do índice Ibovespa.

|  |
|--|
| <b>Regressão Linear para Sentiment Index usando pares / modificadores [Sem treinamento]:</b> |
| <b>Coefficiente:</b> 0.02063456288852657   |
| <b>Intercepto:</b> -0.005388650384840607   |
| <b>MSE:</b> 0.00037883058629932385   |
| <b>R²:</b> 0.012578164060659813  |
| <b>Regressão Linear para Sentiment Index usando BERT [Sem treinamento]:</b>                  |
| <b>Coefficiente:</b> 0.8856502855793893  |
| <b>Intercepto:</b> 0.006970540376851941  |
| <b>MSE:</b> 0.0003817301879592467  |
| <b>R²:</b> 0.005020353001888633  |
| <b>Regressão Linear para Sentiment Index usando FinBERT-PT-BR [Sem treinamento]:</b>         |
| <b>Coefficiente:</b> -0.00172459143118286  |
| <b>Intercepto:</b> -0.001529312136055326   |
| <b>MSE:</b> 0.000382625220350364   |
| <b>R²:</b> 0.002687451280579678  |

Fonte: Elaboração Própria.

Os resultados das regressões lineares fornecem informações sobre a relação entre cada índice de sentimento e a variação percentual do Ibovespa.

O coeficiente representa a inclinação da linha de regressão, ou seja, a quantidade pela qual a variação percentual do Ibovespa muda para cada unidade de mudança no índice de sentimento. Um coeficiente positivo indica que à medida que o índice de sentimento aumenta, a variação percentual do Ibovespa tende a aumentar. Um coeficiente negativo indica que à medida que o índice de sentimento aumenta, a variação percentual do Ibovespa tende a diminuir.

O intercepto representa o valor esperado da variação percentual do Ibovespa quando o índice de sentimento é zero. Serve como um ponto de referência para a linha de regressão.

MSE (*Mean Squared Error*) mede a média dos quadrados dos erros, ou seja, a média das diferenças quadradas entre os valores reais e os valores previstos. Valores menores de MSE indicam que o modelo tem melhor desempenho ao prever a variação percentual do Ibovespa.

$R^2$  (Coeficiente de Determinação) mede a proporção da variabilidade na variação percentual do Ibovespa que pode ser explicada pelo índice de sentimento. Valores de  $R^2$  variam de 0 a 1, onde valores mais próximos de 1 indicam um melhor ajuste do modelo aos dados. Um  $R^2$  muito baixo indica que o índice de sentimento explica muito pouco da variação na variação percentual do Ibovespa.

Para o Índice de Sentimentos obtido por meio do modelo com pares e modificadores, sem treinamento, foi obtido um  $R^2$  de 0.0126. Isso significa que apenas 1.26% da variação percentual do Ibovespa é explicada pelo índice de sentimento. Isto sugere que este resultado para o índice de sentimento não é um bom preditor.

Para o Índice de Sentimentos obtido por meio do modelo com BERT, sem treinamento, foi obtido um  $R^2$  de 0.0050. Isso significa que apenas 0.5% da variação percentual do Ibovespa é explicada pelo índice de sentimento. Isto sugere que este resultado obtido para o índice de sentimento também não é um bom preditor.

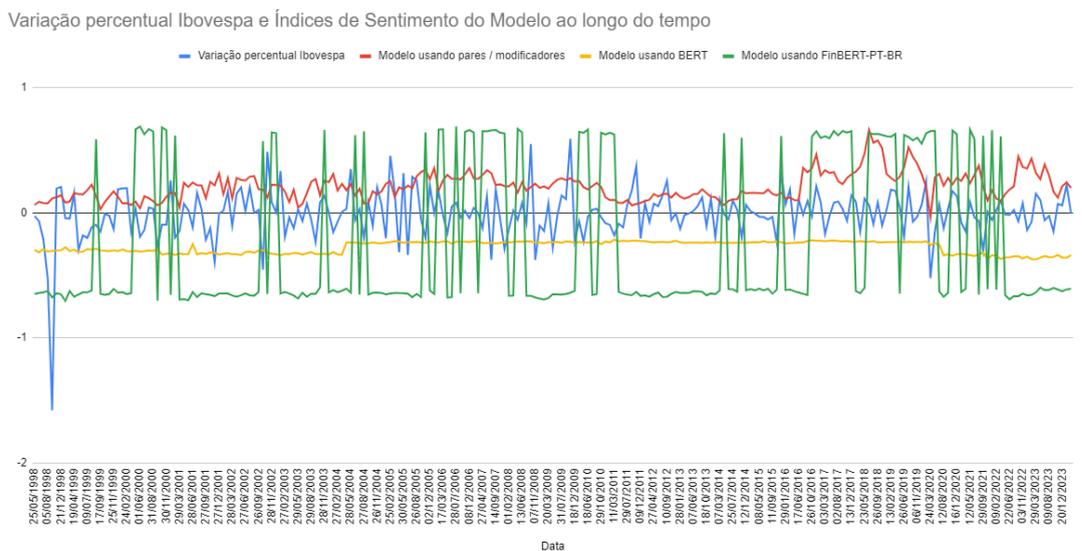
Para o Índice de Sentimentos obtido por meio do modelo com FinBERT-PT-BR, sem treinamento, foi obtido um  $R^2$  de 0.0027. Isso significa que apenas 0.27% da variação percentual do Ibovespa é explicada pelo índice de sentimento. Isto sugere que este resultado obtido para o índice é um bom preditor ainda pior.

Sendo assim, nenhum dos índices de sentimento parece ser um bom preditor da variação percentual do Ibovespa sem treinamento, já que todos os valores de  $R^2$  são muito baixos, indicando que a maior parte da variação na variação percentual do Ibovespa não é explicada pelos índices de sentimento utilizados.

## 6.1 Resultado dos Índices de Sentimento ao longo do tempo

Multiplicando o valor da variação percentual do índice Ibovespa por 10, e com o valor do índice obtido pelo modelo usando BERT sendo multiplicado por 30, para melhorar a visualização, foi possível mostrar o resultado dos 3 modelos no mesmo gráfico, conforme Figura 18 abaixo, que demonstra a ausência de correlação entre os índices de sentimentos obtidos sem treinamento e a variação percentual do índice Ibovespa.

Figura 18: Variação dos valores dos Índices de Sentimento obtidos ao longo do tempo.



Fonte: Elaboração própria.

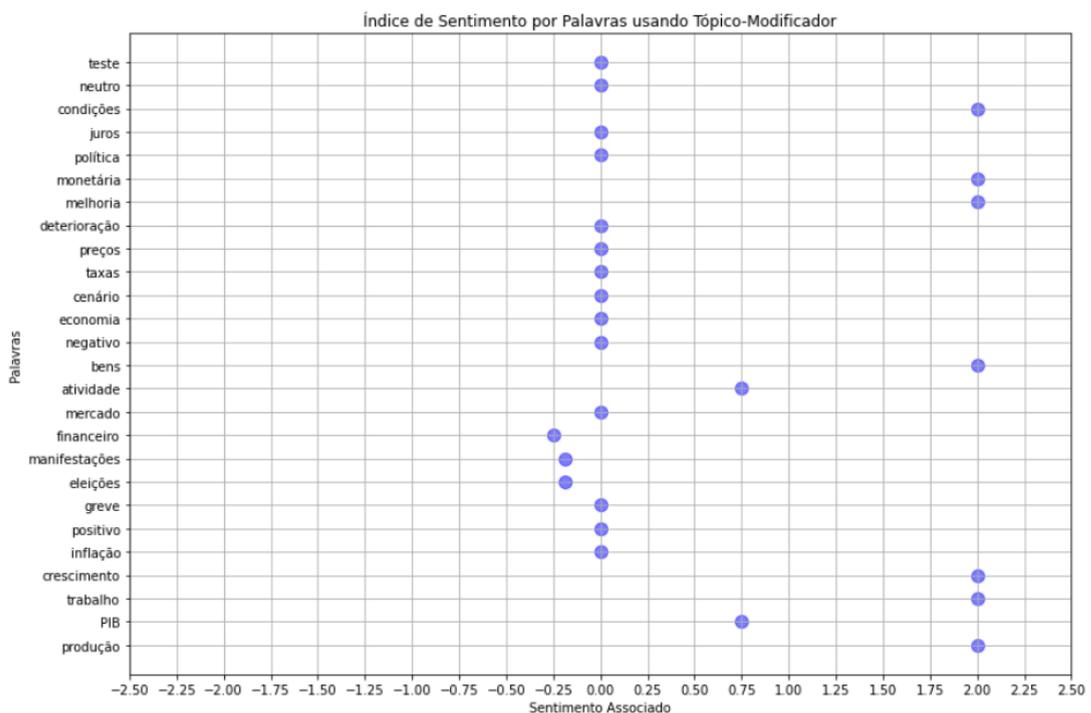
## 6.2 Resposta ao Impulso dos Modelos

Por fim, também foi obtida a resposta a uma entrada impulsiva para os 3 modelos propostos, de forma a melhor compreender seus comportamentos.

No entanto, definir uma entrada impulsiva para modelos de análises textuais pode ser desafiador, uma vez que a menor entrada possível para os modelos é de apenas uma palavra, entretanto existe uma infinidade de palavras candidatas.

Por isso, foi realizada a análise de sentimento de 22 palavras analisadas individualmente, que foram escolhidas com base na análise das palavras mais frequentes nos comunicados, e com base em temas relevantes para esse trabalho, conforme mostrado na Figura 19, na Figura 20 e na Figura 21 abaixo:

Figura 19: Resposta ao impulso do modelo usando pares tópico/modificador.



Fonte: Elaboração Própria.

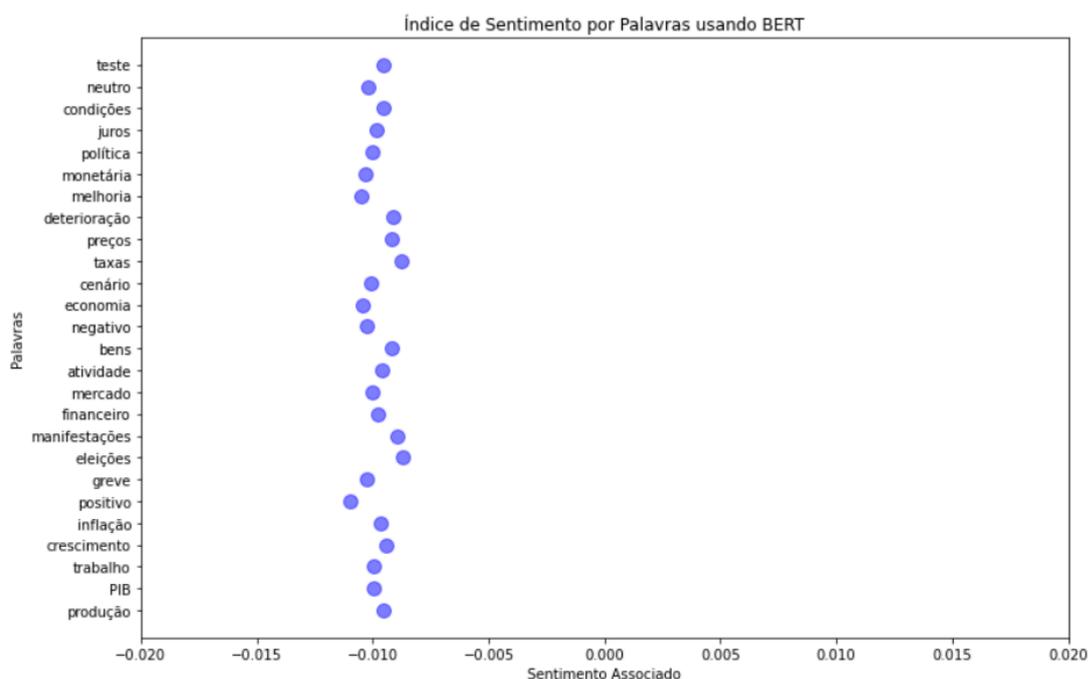
Neste gráfico, é possível observar que apenas as palavras que tiveram um valor inicial definido dentro da declaração dos modificadores possuem um valor para o sentimento diferente de 0.

Além disso, também é possível observar como o modelo se comporta ao processar uma única palavra sozinha, caso essa palavra tenha sido inicializada dentro da declaração dos modificadores.

Como todos os modificadores foram inicializados com pesos iguais a “0”, “0.5”, “-0.5”, “1” ou “-1”, pode-se perceber que há um pequeno deslocamento de todos os sentimentos calculados pelo modelo para a direita, ou seja, para o lado positivo.

Mesmo as palavras que apresentaram um sentimento negativo - abaixo de zero - foram influenciadas por esse deslocamento, pois nenhum modificador chegou a apresentar um valor para o índice de sentimento igual a “-0.5” ou “-1”. Além disso, há modificadores que excedem o peso “1” inicial, após o processamento.

Figura 20: Resposta ao impulso do modelo usando BERT:

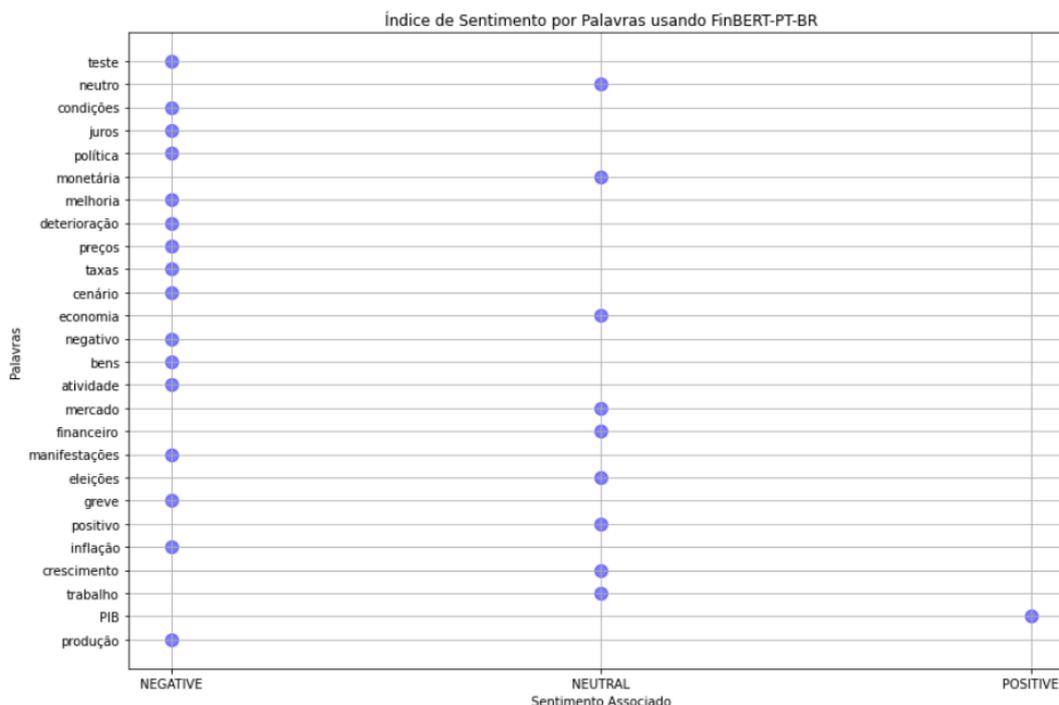


Fonte: Elaboração Própria.

Analisando o resultado da resposta a uma entrada impulsiva, ou seja, a uma única palavra, do modelo utilizando o BERT original, é possível observar claramente a distribuição do valor de alguns dos tensores aos quais este trabalho buscou adicionar pesos com a finalidade de tentar desenvolver um índice de sentimento com o resultado do somatório, ligeiramente

deslocados para a esquerda, ou seja, para o lado negativo.

Figura 21: Resposta ao impulso do modelo usando FinBERT-PT-BR.



Fonte: Elaboração Própria.

Analisando o resultado da resposta a uma entrada impulsiva, ou seja, a uma única palavra, do modelo utilizando o FinBERT-PT-BR, é possível perceber que o pré-treinamento realizado possivelmente o tornou bastante pessimista, entendendo praticamente todos os termos testados como negativos ou neutros, com exceção do termo “PIB”. Até mesmo o termo “positivo” teve sua classificação de sentimento dada como neutra e o termo “teste” teve a classificação dada como negativa.

Isso também pode ter acontecido por influência do fato de haver um leve desequilíbrio na dispersão de tensores do BERT original, usado como base para o FinBERT e para FinBERT-PT-BR, pois foi possível notar na resposta ao impulso do modelo que há um leve deslocamento da média da dispersão em relação ao 0, para a esquerda, de forma que todos os valores de tensores observados possuíam valor negativo.

Este resultado com maior tendência negativa tende a influenciar os resultados das predições, de forma a melhorar a assertividade do modelo para comunicados negativos, mas diminui a assertividade do modelo para

comunicados positivos, conforme também é possível observar nos resultados obtidos com esse trabalho.

## 7. Conclusão

A análise de sentimento das comunicações do Banco Central do Brasil (BCB), por meio de modelos de inteligência artificial, revelou importantes *insights* sobre a relação entre o tom dessas comunicações e as variações nos preços dos ativos financeiros. Utilizando análises estatísticas sobre o uso de palavras e modelos de Processamento de Linguagem Natural (PLN) como o modelo Léxico, o BERT e o FinBERT-PT-BR, este trabalho procurou capturar a essência sentimental dos comunicados do Comitê de Política Monetária (COPOM) e correlacionar essas emoções com a performance do índice Ibovespa. Os modelos foram utilizados para identificar sentimentos positivos, negativos e neutros nas comunicações do COPOM.

A literatura revelou que comunicados com tom positivo estavam associados a aumentos no preço das ações, enquanto os comunicados com tom negativo frequentemente correlacionaram-se com quedas nos preços das ações e aumentos nas expectativas de juros futuras. Isso evidencia que os agentes econômicos, representados no estudo pelo Ibovespa, reagem não apenas ao conteúdo explícito das políticas anunciadas, mas também ao sentimento subjacente nas comunicações do BCB.

Nas análises estatísticas realizadas no capítulo 5, observou-se que as palavras mais usadas nos comunicados refletem preocupações variáveis ao longo do tempo, mas palavras como “inflação” e “preços” foram predominantes durante todo o período, especialmente em períodos de incerteza.

Picos na frequência de termos específicos, como os dois citados, correlacionaram-se com eventos de grande impacto na sociedade, como as manifestações de julho de 2013 citadas na introdução, entre outros momentos de instabilidade política e econômica.

A análise mostrou que durante esses períodos de incerteza houve um aumento notável no uso de palavras associadas a preocupações

econômicas e políticas nas reuniões do COPOM, analisadas neste estudo por meio de suas atas.

Durante o período de análise, focado em comunicados divulgados a partir da adoção do regime de câmbio flutuante em 1999, os resultados mostraram que os modelos utilizados apresentaram variações no grau de precisão.

O modelo FinBERT-PT-BR demonstrou uma capacidade razoável de compreensão do sentimento geral dos comunicados, acertando o sentido do movimento do Ibovespa no dia seguinte após a divulgação do comunicado em aproximadamente 48% dos casos, e obtendo 67% de precisão na análise de comunicados com sentimento adjacente negativo. No entanto, a eficácia preditiva em termos de magnitude do movimento foi limitada, indicando que embora o modelo possa capturar o tom geral, ele ainda encontra desafios de treinamento em prever a intensidade das reações do mercado.

Por outro lado, o modelo Léxico teve uma acurácia inferior, especialmente em contextos de alta complexidade linguística, e o BERT apresentou dificuldades em captar nuances específicas do contexto financeiro brasileiro.

Além disso, a aplicação de técnicas de regressão linear evidenciou que a maioria dos modelos apresentou coeficientes de determinação ( $R^2$ ) muito baixos, sugerindo que os índices de sentimento, conforme calculados, explicam uma fração mínima da variação no índice Ibovespa. Este achado ressalta a complexidade do mercado financeiro e a necessidade de melhoria nos algoritmos de treinamento dos modelos para determinar o sentimento expresso nas comunicações oficiais com maior precisão.

A pesquisa também sublinha a importância da clareza e transparência nas comunicações do BCB. Uma comunicação clara pode ajudar a alinhar as expectativas do mercado, reduzindo a volatilidade e promovendo um ambiente econômico mais estável. Assim, a análise de sentimento pode servir como uma ferramenta adicional para os formuladores de políticas econômicas, auxiliando na compreensão de como suas comunicações são percebidas pelo mercado e ajustando suas estratégias de acordo.

Conclui-se que, embora a análise de sentimento das comunicações do COPOM através de modelos de PLN e inteligência artificial possa oferecer *insights* valiosos, há necessidade de aprimorar as técnicas de treinamento utilizadas para capturar melhor a complexidade das reações do mercado.

A integração de técnicas de aprendizado de máquina para análise macroeconômica também apresenta outras limitações e desafios, pois a qualidade dos dados é uma questão crucial, uma vez que modelos de ML dependem de dados precisos e abrangentes, e a presença de ruído ou dados faltantes pode comprometer a precisão das previsões. Além disso, modelar certos aspectos econômicos, como choques exógenos ou comportamentos irracionais do mercado, permanece um desafio significativo.

Este estudo abre caminho para futuras pesquisas que poderiam incluir a análise de outros tipos de comunicação do BCB, a aplicação de técnicas mais avançadas de treinamento para melhorar a precisão das previsões aqui realizadas ou estudo da correlação com outros Bancos Centrais.

## Referências

ALFIERI, L.; ERATALAY, M. H.; LAPITSKAYA, D.; e SHARMA, R. **The Effects of the ECB Communications on Financial Markets before and during COVID-19 Pandemic.** School of Economics and Business Administration, p. 80-95, 2022.

BANCO CENTRAL DO BRASIL. **Relatório de Inflação.** Disponível em: <https://www.bcb.gov.br/content/ri/relatorioinflacao/199906/RELINF199906-ri199906P.pdf>. Acesso em: 13 de junho de 2024.

BENDER, E. M.; GEBRU, T.; MCMILLAN-MAJOR, A.; SHMITCHELL, S. **On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?** In: Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, p. 610-623, 2021.

BERNANKE, B. S. **The Effects of the Great Recession on Central Bank Doctrine and Practice.** Observações na 56ª Conferência Econômica, Federal Reserve Bank de Boston.”. Disponível em: <https://www.federalreserve.gov/newsevents/speech/bernanke20111018a.htm> , Acesso em 06/03/2024. 2011.

BROWN, T. B. et al. **Language Models are Few-Shot Learners.** Cornell University. Disponível em: <https://arxiv.org/abs/2005.14165>. Acesso em: 5 jun. 2024.

CASTRO, P. R.; & LIMA, A. F. **Impactos dos movimentos do S&P 500 sobre o mercado de ações brasileiro.** Revista de Economia e Finanças, 18(2), 110-130. 2020.

BU, C.; ROGERS, J.; WU, W.. **A Unified Measure of Fed Monetary Policy Shocks.** Disponível em: <https://www.federalreserve.gov/econres/feds/files/2019043pap.pdf>, Acessado em 19/12/2023. 2019.

CIRILLO, C. H. **MBL, 2013 a 2018: Trajetória Recente e Contradições do Neoliberalismo no Brasil.** 2024. 120 f. Dissertação (Mestrado) - Curso de Economia, Universidade Estadual de Campinas (UNICAMP), Campinas, 2024.

CRESPO, S.; FERREIRA, R. **Exchange Rate Policy, Monetary Policy and Economic Performance in Brazil.** Brazilian Journal of Political Economy, 38(4), 776-795. 2018.

DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding.** In: Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers), p. 4171-4186, 2019. Minneapolis, Minnesota. Disponível em: <https://aclanthology.org/N19-1423/>. Acessado em 07/06/2024.

DUARTE, C. A. P. 2020 **Os efeitos de choques de incerteza na economia brasileira: uma abordagem VAR com sign restrictions.** 2020. 67 f. Dissertação (Mestrado) - Curso de Economia, Insper, 2020.

DOH, T., KIM, S., e YANG, S. K. X. 2021. **How You Say It Matters: Text Analysis of FOMC Statements Using Natural Language Processing.** 2021. Federal Reserve Bank of Kansas City, 2021. Disponível em: <https://www.kansascityfed.org/research/economic-review/how-you-say-it-matters-text-analysis-of-fomc-statements-using-natural-language-processing/>. Acessado em 07/06/2024.

FEDERAL OPEN MARKET COMMITTEE. **Federal Open Market Committee.** Disponível em: [https://www.federalreserve.gov/monetarypolicy/fomc\\_historical.htm](https://www.federalreserve.gov/monetarypolicy/fomc_historical.htm), Acessado em 19/12/2023. 2022.

FERREIRA, M. R.; SANTOS, J. P. **VIX e sua influência nos mercados financeiros globais.** Revista de Economia Internacional, 19(1), 54-70. 2020.

FRIEDMAN, M. **Uma Estrutura Teórica para Análise Monetária.** 1971.

GARDNER, B.; SCOTTI, C.; e VEGA, C. **Words Speak as Loudly as Actions: Central Bank Communication and the Response of Equity Prices to Macroeconomic Announcements**. Finance and Economics Discussion Series 2021-074. Washington: Board of Governors of the Federal Reserve System, <https://doi.org/10.17016/FEDS.2021.074>. 2021.

GAO, J. ZHANG; C. ZHOU, T. **Computational Socioeconomics**. Preprint arXiv, 2019. Disponível em: <https://arxiv.org/abs/1905.06166>. Acesso em 08/06/2024.

GOODFELLOW, I. BENGIO; Y. COURVILLE, A. 2016. **Deep Learning**. MIT Press, 2016.

GARCIA, M. G. P. e COSTA JR., N. C. A. **Mercado Financeiro: Análise de Risco e Retorno**. Rio de Janeiro: Elsevier, 2015.

GUSMÃO, L. G. . **Aprendizado de Máquina e Dados Socioeconômicos**. 2020. TCC (Graduação) - Curso de Engenharia Elétrica, Universidade Estadual de Campinas (UNICAMP), Campinas, 2020.]

HASTIE, T.; FRIEDMAN, J.; TIBSHIRANI. **The Elements of Statistical Learning**. SPRINGER, 2001.

HINTON, G. e. SALAKHUTDINOV, R. R. 2006. **Reducing the dimensionality of data with neural networks**. Science, v. 313(5786), p. 504-507, 2006.

HOCHREITER, S.; SCIMIDHUBER, J. **LONG SHORT-TERM MEMORY**. Disponível em: <https://www.bioinf.jku.at/publications/older/2604.pdf>. Acesso em 06 de abril de 2024.

JAGTAP, A. S. **Data Driven**. 2019.

KE, Z. T., KELLY, B. T. e XIU, D. **Predicting Returns With Text Data**. National Bureau of Economic Research, 5-55. 2019 Disponível em: <https://www.nber.org/papers/w26186>. Acesso em 08/06/2024. 2019.

KEYNES, John Maynard. **A Teoria Geral do Emprego, do Juro e da Moeda**. 1936.

KRUGMAN, Paul. 2015. **The case for cuts was a lie. Why does Britain still believe it?** The austerity delusion. Disponível em: <https://www.theguardian.com/business/ng-interactive/2015/apr/29/the-austerity-delusion>. Acesso em 10 de junho de 2024.

Lima, T. R.; Barbosa, F. A. (2018). **Impactos do VIX nos fluxos de capital para mercados emergentes**. Revista Brasileira de Economia, 20(3), 75-90.

LOFFE, S.; SZEGEDY, C. **Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift**. 2015.

LOUGHRAN, T.; & MCDONALD, B. **When Is a Liability Not a Liability? Textual Analysis, Dictionaries and 10-Ks**. The Journal Of Finance, LXVI, 5-31. 2011.

MAHESH, B. 2020. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**, v. 9, p. 381–386, 2020.

MARTINS, L. A.; SOUSA, M. R. **Volatilidade do S&P 500 e suas implicações para a B3**. Estudos de Mercado Financeiro, 22(1), 80-95. 2019.

MARX, K. **Introdução à Contribuição para a Crítica da Economia Política**. São Paulo, Expresso Popular, 2008.

MARX, K. **O Capital**. São Paulo, Boitempo, 2023.

MÁXIMO, P. H. M. **A influência da inflação e da taxa de juros no desenvolvimento econômico do Brasil**. 2023. TCC (Graduação) - Curso de Engenharia de Produção Mecânica - Universidade Estadual Paulista (Unesp), Guaratinguetá, 2023. Disponível em: <<http://hdl.handle.net/11449/217925>>. Acesso em 19/12/2023.

MÁTÉ Á., SEBŐK M. e BARCZIKAY T., 2021. **The effect of central bank communication on sovereign bond yields: The case of Hungary**. Centre

for Social Sciences, Budapest, Hungria.

Disponível em: <https://doi.org/10.1371/journal.pone.0245515>. Acesso em 10 de junho de 2024.

MENDONÇA, H. F. **Política monetária e o mercado de capitais: uma análise dos impactos das decisões do COPOM no Ibovespa**. Revista Brasileira de Economia, v. 63, n. 2, p. 123-146, 2009.

MÖLLER, Rouven & REICHMANN, Doron. 2021. **ECB Language and Stock Returns – A Textual Analysis of ECB Press Conferences**. 2021. 41 f. Ruhr-Universität Bochum Department of Finance and Bankings, 2021.

NIERI, André Henrique Inostroza. 2021. **Democracia Americana: Tecnologia, Ideias e Instituições**. 2021. TCC (Graduação) - Curso de Economia, Universidade Estadual de Campinas (UNICAMP), Campinas, 2021.

OLIVEIRA, F. B. **A influência da taxa de câmbio sobre as exportações brasileiras**. Revista Brasileira de Gestão e Desenvolvimento Regional, 14(1), 212-227. 2018.

PANG, B.; LEE, L. **Opinion Mining and Sentiment Analysis**. Disponível em: <https://www.nowpublishers.com/article/Details/INR-011>. Acesso em 10 de junho de 2024.

PEREIRA, L. A. **Impacto das variações cambiais sobre a rentabilidade das empresas exportadoras e o mercado acionário brasileiro**. Revista de Finanças Aplicadas, 4(2), 1-17. 2015.

MISHKIN, F.S. **The Economics of Money**, Banking and Financial Markets. Pearson, 2015.

RASMUS, Jack. **Alexander Hamilton e as origens do Fed**. Lexington Books, Lanham, 2020.

RIOS, Joan Lima. ROSA, Lukas Silva da. **Predição de casos de Covid-19 utilizando técnicas de Aprendizado de Máquina**. 2022. 33 f. TCC

(Graduação) - Curso de Engenharia Elétrica, Universidade Estadual de Campinas (UNICAMP), Campinas, 2022.

SANTOS, Lucas L.; BIANCHI, Reinaldo A. C.; COSTA, Anna H. R.. **FinBERT-PT-BR**: análise de sentimento de Textos em Português do Mercado Financeiro. In: BRAZILIAN WORKSHOP ON ARTIFICIAL INTELLIGENCE IN FINANCE (BWAIF), 2., João Pessoa/PB. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2023 . p. 144-155. DOI: <https://doi.org/10.5753/bwaif.2023.231151>. 2023.

SELZER, Fabrício Campos. **Filosofia Política e Prática Econômica: A Experiência Conservadora Americana**. 2020. TCC (Graduação) - Curso de Economia, Universidade Estadual de Campinas (UNICAMP), Campinas, 2020.

SILVA, R. T., & PEREIRA, J. C. **O papel do S&P 500 no contexto financeiro global**. Journal of Global Finance, 29(3), 140-160. 2021.

SIQUEIRA, A. C. **Índices de Mercado: Teoria e Prática no Contexto Brasileiro**. São Paulo: Editora Atlas, 2007.

SMITH, A. **A Riqueza das Nações**. São Paulo, Nova Cultura, 1996.

SOUZA, L. M., & ALMEIDA, R. S. 2019. **Estratégias de investimento e volatilidade**: uma análise do impacto do VIX. Journal de Gestão de Investimentos, 15(4), 100-115. 2019.

SUN, C.; QIU, X.; XU, Y.; HUANG, X. **How to Fine-Tune BERT for Text Classification?** In: China National Conference on Chinese Computational Linguistics, p. 194-206, 2019.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**, MIT Press. 2018.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, Ł.; POLOSUKHIN, I. **Attention is All you Need**. 31st Conference on *Neural Information Processing Systems (NIPS)*. 2017 Long Beach, CA, USA. Disponível em: <https://arxiv.org/abs/1706.03762>. Acesso em

08/06/2024.

YAHOO FINANÇAS. **Bolsa de Valores**. Disponível em:  
<https://br.financas.yahoo.com/>. Acesso em 14 de junho de 2024.

YANG, Z.; DAI, Z.; YANG, Y.; CARBONELL, J.; SALAKHUTDINOV, R.; LE, Q. V. XLNet: **Generalized Autoregressive Pretraining for Language Understanding**. 33rd Conference on Neural Information Processing Systems. Vancouver, Canadá. 2019.

YIELD CURVE MODELS AND DATA, 2019 **“Yield Curve Models and Data”**, <https://www.federalreserve.gov/data/yield-curve-models.htm>, Acessado em 19/12/2023. 2019.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding Machine Learning**: From Theory to Algorithms. Cambridge University Press, 2014.

TESOURO DIRETO. **Histórico de Preços e taxas**. Disponível em:  
<https://www.tesourodireto.com.br/titulos/historico-de-precos-e-taxas.htm>.  
Acesso em: 14 de junho de 2024.

KRICHEVSKY, A.; Sutskever, I.; HINTON, G. E. **Imagenet classification with deep convolutional neural networks**[C]. Advances in Neural Information Processing Systems. 2012.